

# Introducción al Deep Learning

## Ignacio Díaz Blanco

# ¿Qué es el aprendizaje profundo? deep learning (DL)

Yosua Bengio: *El País*, 1 de febrero de 2018 (entrevista)

<https://goo.gl/vkndTo>

“Es un aprendizaje automático que permite a los ordenadores **aprender a partir de ejemplos** y construir sistemas inteligentes”



“... se distingue de otros aprendizajes en que los algoritmos usados se inspiran en las **redes de neuronas**...”

“Decimos que es **profundo** porque los cálculos se efectúan a través de diferentes **niveles de transformación** de datos, de distintas **capas, como nuestro cerebro**”

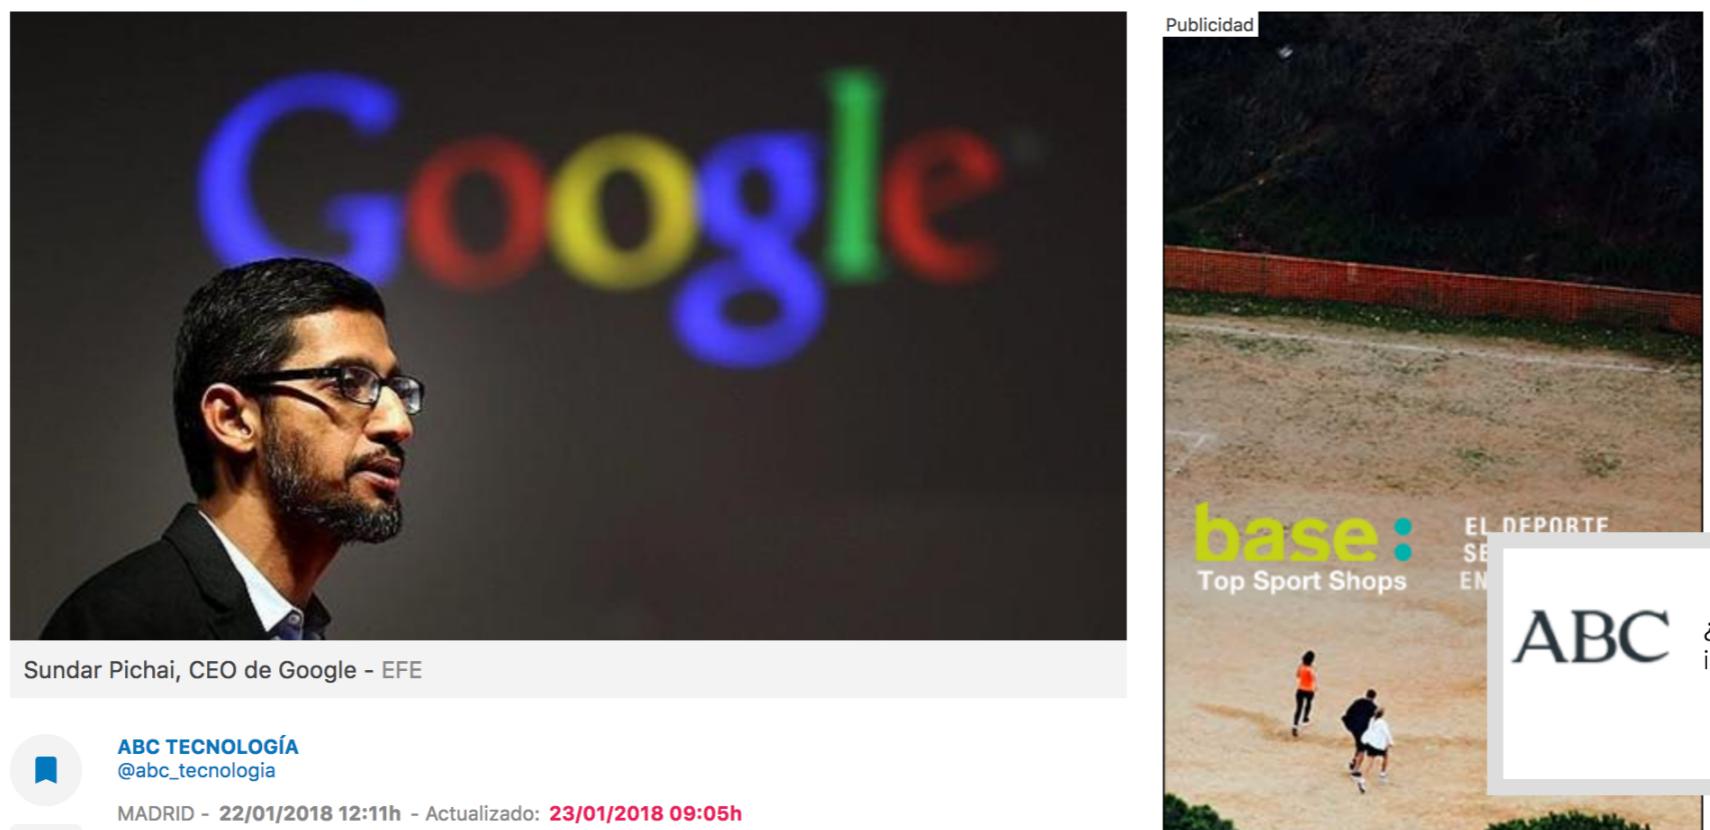


Colin Ware, 2008 “Visual thinking for design”

# ¿Qué es el aprendizaje profundo? impacto futuro

## «La inteligencia artificial tendrá el mismo impacto que la electricidad o el fuego»

- Sundar Pichai, CEO de Google, ha llevado a cabo esta afirmación en una entrevista que se emitirá próximamente en la cadena estadounidense MSNBC



abc.es

Sundar Pichai, CEO de Google, enero de 2018

<https://goo.gl/orH71V>

# ¿Qué es el aprendizaje profundo? impacto futuro

Artículo en Forbes

## “10 Ways Machine Learning Is Revolutionizing Manufacturing”

JUN 26, 2016 @ 08:17 PM

<https://goo.gl/BzYWZa>

### Algunas ideas

- Incrementar capacidad de producción 20%
- Reducir consumo de material 4%
- Aportar datos más relevantes → ajustar acciones (financiación, operaciones, etc.)
- Mejoras en mantenimiento: preventivo, predictivo
- Monitorización de la condición → mejora en la eficiencia de los procesos
- Control de calidad: factores que afectan calidad (productos, empresa: KPI's)

# ¿Dónde está el Deep Learning?

# En el bolsillo...

## chips dedicados en dispositivos móviles



**Apple A17**

From Wikipedia, the free encyclopedia

The Apple A17 Pro is a 64-bit ARM-based system on a chip (SoC) designed by Apple Inc. and manufactured by TSMC.<sup>[4]</sup> It is used in the iPhone 15 Pro and iPhone 15 Pro Max models only.<sup>[3][5]</sup>

**Design**

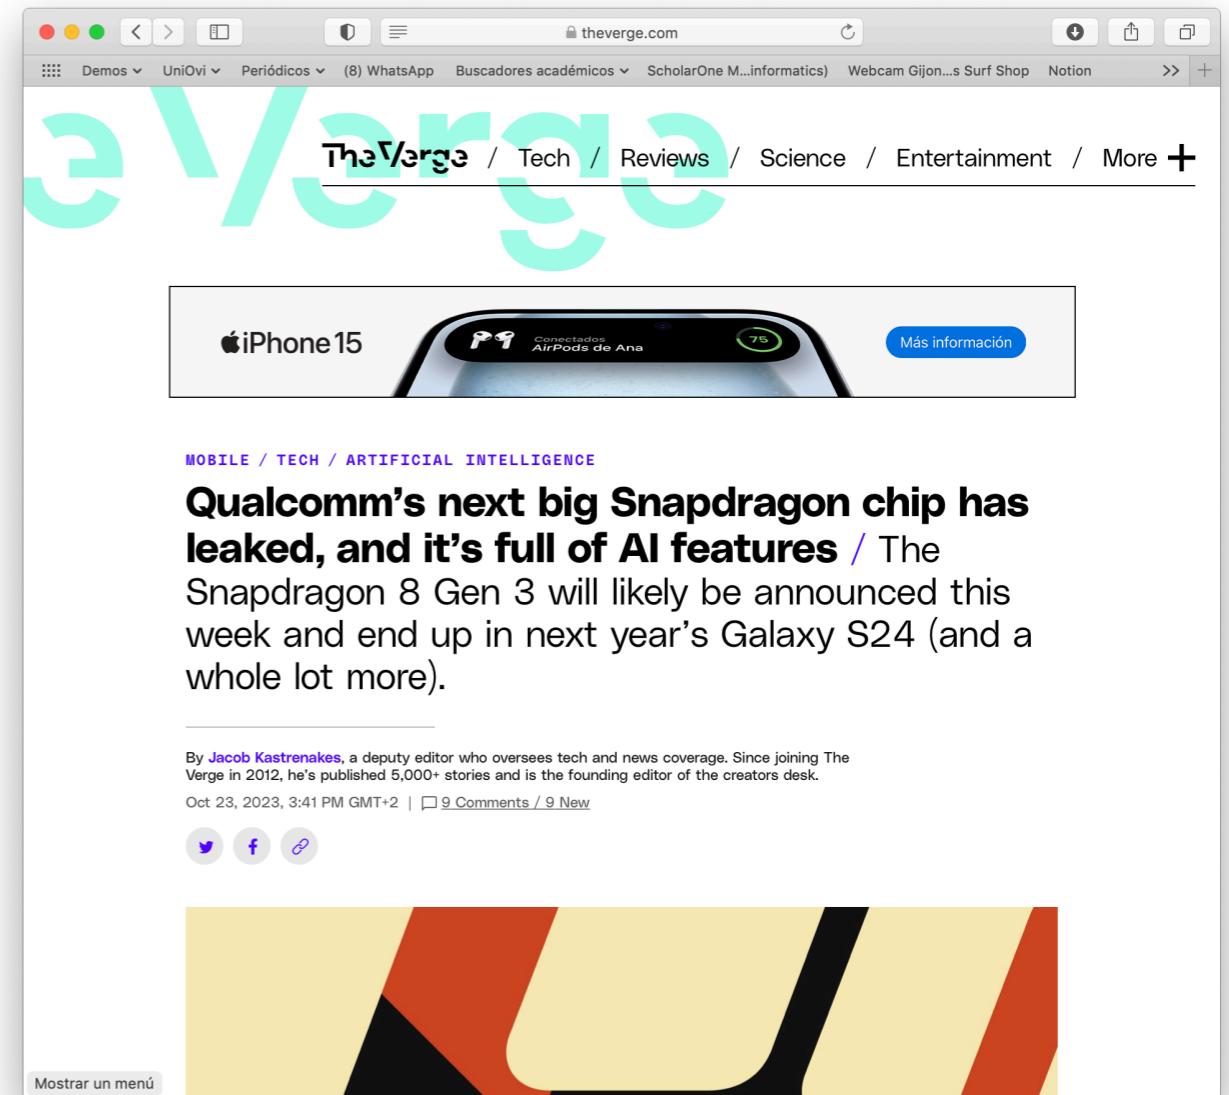
The Apple A17 Pro features an Apple-designed 64-bit six-core CPU with two high-performance cores running at 3.78 GHz, and four energy-efficient cores running at 2.11 GHz.<sup>[2]</sup> Apple claims the new high-performance cores are 10% faster due to its improved branch prediction, and wider decode & execution engines, and the new energy-efficient cores are faster and 3x more efficient than the competition.<sup>[5]</sup> The amount of RAM has increased from 6GB to 8GB.<sup>[6]</sup>

The A17 Pro integrates a new Apple-designed six-core GPU, which Apple claims is 20% faster and their biggest redesign in the history of Apple GPUs, with added hardware accelerated ray tracing and mesh shading support. The 16-core Neural Engine is now capable of 35 trillion operations per second. The A17 Pro also added support for AV1 decoding and USB 3.2 Gen 2 (est. up to 10Gbit/s / 1.25Gbps).<sup>[7]</sup> The A17 Pro contains 19 billion transistors, a 19% increase from the A16's transistor count of 16 billion, and is fabricated by TSMC on their 3 nm N3B process.<sup>[5]</sup>

**Products that include the Apple A17 Pro**

- iPhone 15 Pro & 15 Pro Max

**Comparison of A15, A16 and A17**



**Qualcomm's next big Snapdragon chip has leaked, and it's full of AI features** / The Snapdragon 8 Gen 3 will likely be announced this week and end up in next year's Galaxy S24 (and a whole lot more).

By Jacob Kastrenakes, a deputy editor who oversees tech and news coverage. Since joining The Verge in 2012, he's published 5,000+ stories and is the founding editor of the creators desk.

Oct 23, 2023, 3:41 PM GMT+2 | □ 9 Comments / 9 New

**Physical specifications**

Transistors	19 billion
Cores	6 (4 efficiency, 2 performance) <sup>[3]</sup>
Memory (RAM)	8GB
GPU(s)	Apple-designed 6-core GPU <sup>[3]</sup>

# En cualquier dispositivo...

## PC's, tablets,... todo lo que se conecte a internet

**Reconocimiento de voz**  
Siri, Alexa

**Recomendadores**  
Netflix, Amazon, Google, X (Twitter)

**Etiquetado de imágenes**  
Google, Facebook

# Detección de contenido inapropiado en vídeos de YouTube

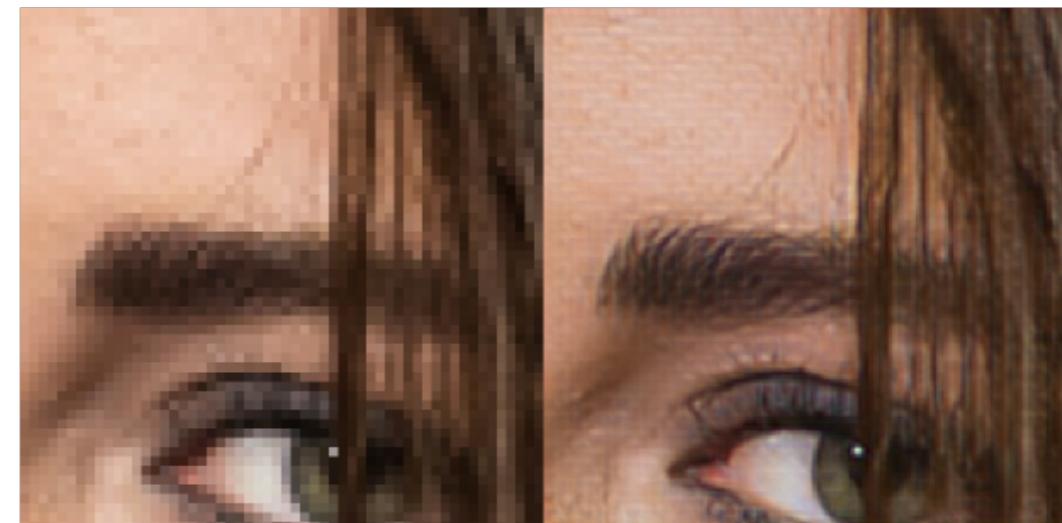
- subidas de vídeos: **400 h/min**
- Sistema IA:  
**identificó 98% de 150.000 archivos retirados**
- Fuerza de trabajo:  
**180.000 personas trabajando 40h/semana**
- Sin embargo, YouTube anunciaba a finales de 2017 que también  
**reforzaría su equipo humano**



fuente: abc tecnología 06/02/2018, <https://goo.gl/bdxfd1>

# Superresolución de imágenes

## generative adversarial networks, GAN



<https://github.com/alexjc/neural-enhance>

¿El truco? la red “alucina”, se inventa los detalles que faltan  
basándose en miles de ejemplos aprendidos

## Cámaras Ricoh PENTAX

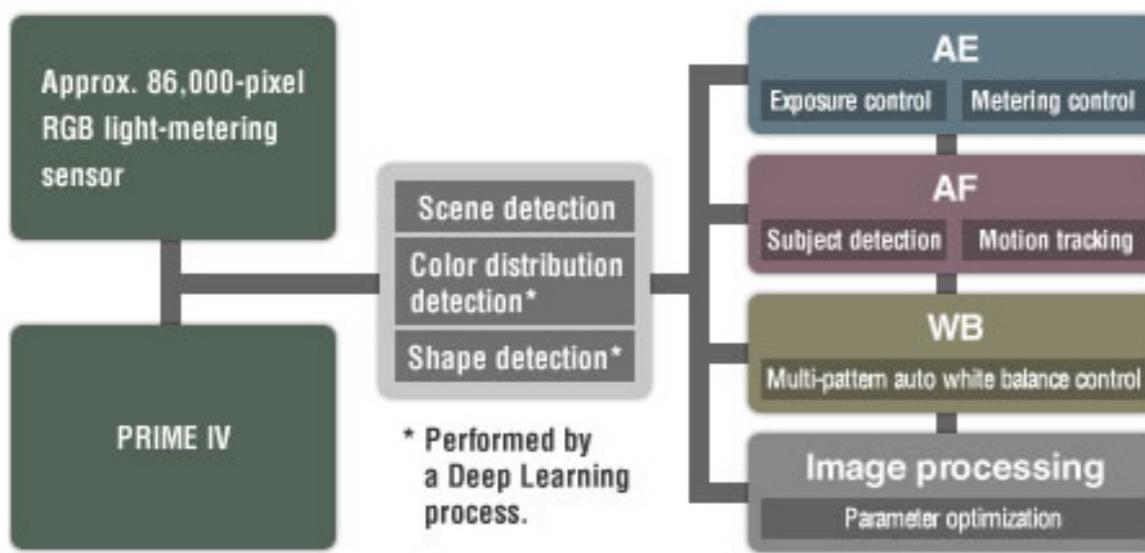
Modo “AUTO”



basándose en datos de sensor RGB  
( ~ 86000 píxeles)

análisis de escenas

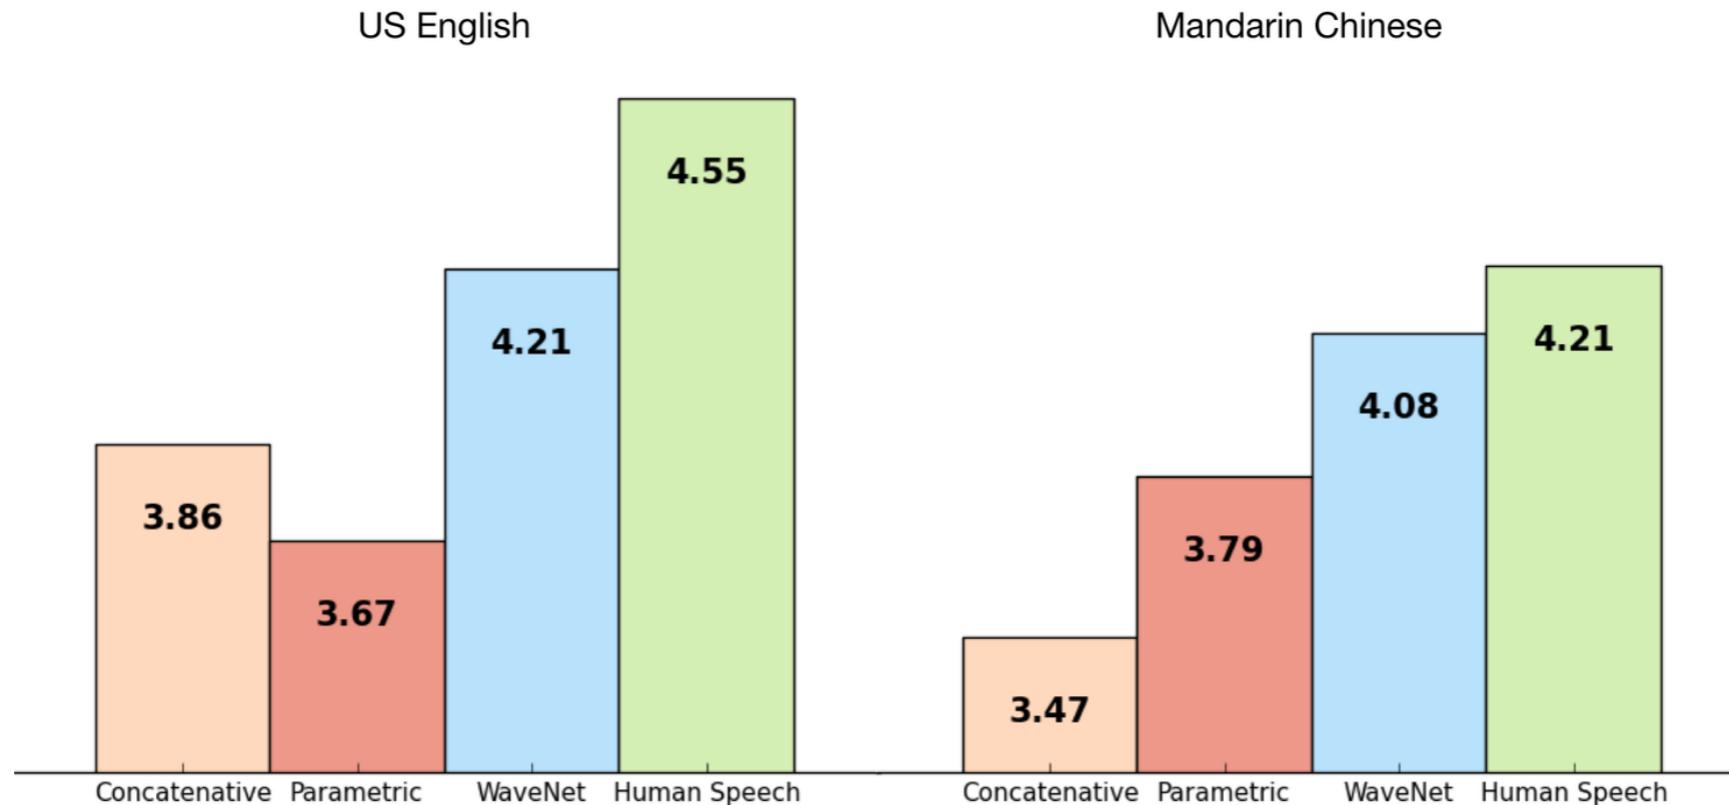
optimiza parámetros de exposición



fuente: página web de Ricoh, <https://goo.gl/BSJAaf>

# Máquinas que hablan

## Síntesis de voz: DeepMind/WaveNet



fuente: <https://deepmind.com/blog/wavenet-generative-model-raw-audio/>

En la página web, se puede comparar  
el resultado de WaveNet con otros métodos

# Arte: Style Transfer

minimización de distancias entre “feature representations”

$$\mathcal{L}(\vec{p}, \vec{a}, \vec{x}) = \alpha \mathcal{L}_{\text{contenido}}(\vec{p}, \vec{x}) + \beta \vec{L}_{\text{estilo}}(\vec{a}, \vec{x})$$



fuente: <https://github.com/jcjohnson/neural-style>

## A Neural Algorithm of Artistic Style

Leon A. Gatys,<sup>1,2,3\*</sup> Alexander S. Ecker,<sup>1,2,4,5</sup> Matthias Bethge<sup>1,2,4</sup>

<sup>1</sup>Werner Reichardt Centre for Integrative Neuroscience  
and Institute of Theoretical Physics, University of Tübingen, Germany

<sup>2</sup>Bernstein Center for Computational Neuroscience, Tübingen, Germany

<sup>3</sup>Graduate School for Neural Information Processing, Tübingen, Germany

<sup>4</sup>Max Planck Institute for Biological Cybernetics, Tübingen, Germany

<sup>5</sup>Department of Neuroscience, Baylor College of Medicine, Houston, TX, USA

\*To whom correspondence should be addressed; E-mail: leon.gatys@bethgelab.org

In fine art, especially painting, humans have mastered the skill to create unique visual experiences through composing a complex interplay between the content and style of an image. Thus far the algorithmic basis of this process is unknown and there exists no artificial system with similar capabilities. However, in other key areas of visual perception such as object and face recognition near-human performance was recently demonstrated by a class of biologically inspired vision models called Deep Neural Networks.<sup>1,2</sup> Here we introduce an artificial system based on a Deep Neural Network that creates artistic images of high perceptual quality. The system uses neural representations to separate and recombine content and style of arbitrary images, providing a neural algorithm for the creation of artistic images. Moreover, in light of the striking similarities between performance-optimised artificial neural networks and biological vision,<sup>3-7</sup> our work offers a path forward to an algorithmic understanding of how humans create and perceive artistic imagery.

1

fuente: <https://arxiv.org/abs/1508.06576>

# Conducción autónoma (reinforcement learning)



fuente YouTube: <https://youtu.be/DeE8tntTSPI>

## Proyecto DeepDrive en Berkeley

<https://deepdrive.berkeley.edu/>



Google search results for "inteligencia artificial hacienda".

Results:

- Diario de Noticias de Álava**  
https://www.noticiasdealava.eus › alava › 2023/11/22 ...  
[La Hacienda de Álava recurrirá a la inteligencia artificial ...](#)  
hace 2 días — La Hacienda de Álava recurrirá a herramientas vinculadas con la **inteligencia artificial** para luchar contra el fraude fiscal, como es el caso de un sistema ...
- Libre Mercado**  
https://www.libremercado.com › Libre Mercado ...  
[De la inspección física a los algoritmos](#)  
31 oct 2023 — Hacienda considera que ha tenido una "experiencia satisfactoria en la utilización de la **inteligencia artificial** como forma de proporcionar información ...
- Antifraucv**  
https://www.antifraucv.es › inteligencia-artificial-y-luc... ...  
[Inteligencia Artificial y lucha contra la corrupción](#)  
hace 3 días — La **inteligencia artificial** puede ayudar a combatir la corrupción al detectar irregularidades y conflictos de interés mediante el análisis masivo de datos. Para ...
- FiscalBlog**  
https://fiscalblog.es › Derechos fundamentales ...  
[¿Puede la Agencia Tributaria utilizar la Inteligencia Artificial?](#)  
29 oct 2023 — 117 RGAT, permitan al Ministro de **Hacienda** establecer con carácter general una obligación allí donde el art. 96.2 LGT establece un derecho.» Este ...

(fecha consulta 24/11/2023)

Google search results for "inteligencia artificial justicia juzgado".

Results:

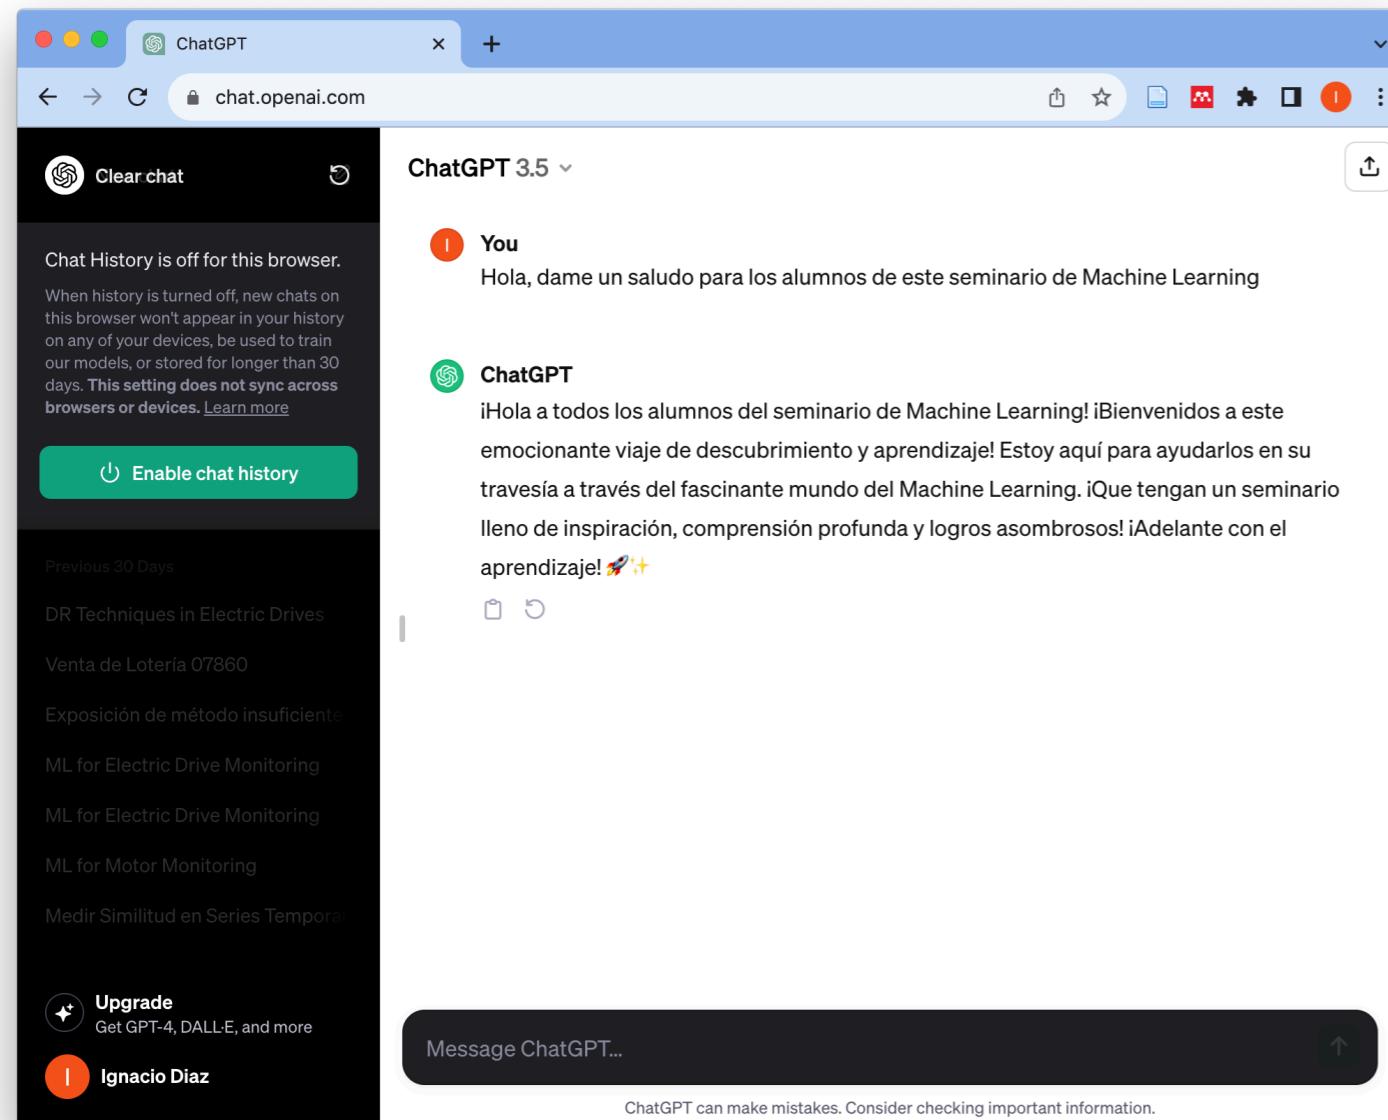
- UNESCO**  
https://www.unesco.org › rule-law › mooc-judges ...  
[La IA y el Estado de derecho: Fortalecimiento ...](#)  
8 nov 2023 — Los sistemas judiciales a nivel mundial utilizan la **Inteligencia artificial** (IA) para analizar grandes cantidades de datos jurídicos con el objetivo de ayudar a ...
- Europa Press**  
https://www.europapress.es › madrid › noticia-juzgado... ...  
[Los juzgados madrileños dispondrán a final de año de un ...](#)  
25 oct 2023 — Los **juzgados** de la Comunidad de Madrid dispondrán "a finales de años" de un buscador basado en **Inteligencia Artificial** (IA) para poder consultar toda la ...
- El Derecho**  
https://elderecho.com › justicia-pone-en-marcha-un-pr... ...  
[Justicia pone en marcha un programa de hyper ...](#)  
10 nov 2023 — Además, a través del uso de la RPA -automatización robótica de procesos-, y la combinación con técnicas de **inteligencia artificial** ... **juzgado** para lograr su ...
- Europa Press**  
https://www.europapress.es › economía › noticia-minis... ...  
[El Ministerio de Justicia y NTT Data colaboran para ...](#)  
10 nov 2023 — ... **inteligencia artificial** (IA) para mejorar la eficiencia de los órganos ... **juzgado** para lograr su adaptación digital y ser parte fundamental del proyecto ...
- Derecho práctico**  
https://www.derechopractico.es › el-ministerio-de-justi... ...  
[El Ministerio de Justicia pone en marcha un programa de ...](#)  
10 nov 2023 — A través de la combinación de diferentes tecnologías basadas en robotización e **inteligencia artificial**, este programa fomentará la eficiencia de los órganos ...
- Ámbito Jurídico**  
https://www.ambitojuridico.com › columnista-impresso ...  
[Ámbito Jurídico](#)

(fecha consulta 24/11/2023)

# Modelos de Lenguaje

## chatGPT, claude.ai, perplexity.ai, ...

### ChatGPT



Chat History is off for this browser.

When history is turned off, new chats on this browser won't appear in your history on any of your devices, be used to train our models, or stored for longer than 30 days. This setting does not sync across browsers or devices. [Learn more](#)

**Enable chat history**

Previous 30 Days

- DR Techniques in Electric Drives
- Venta de Lotería 07860
- Exposición de método insuficiente
- ML for Electric Drive Monitoring
- ML for Electric Drive Monitoring
- ML for Motor Monitoring
- Medir Similitud en Series Temporales

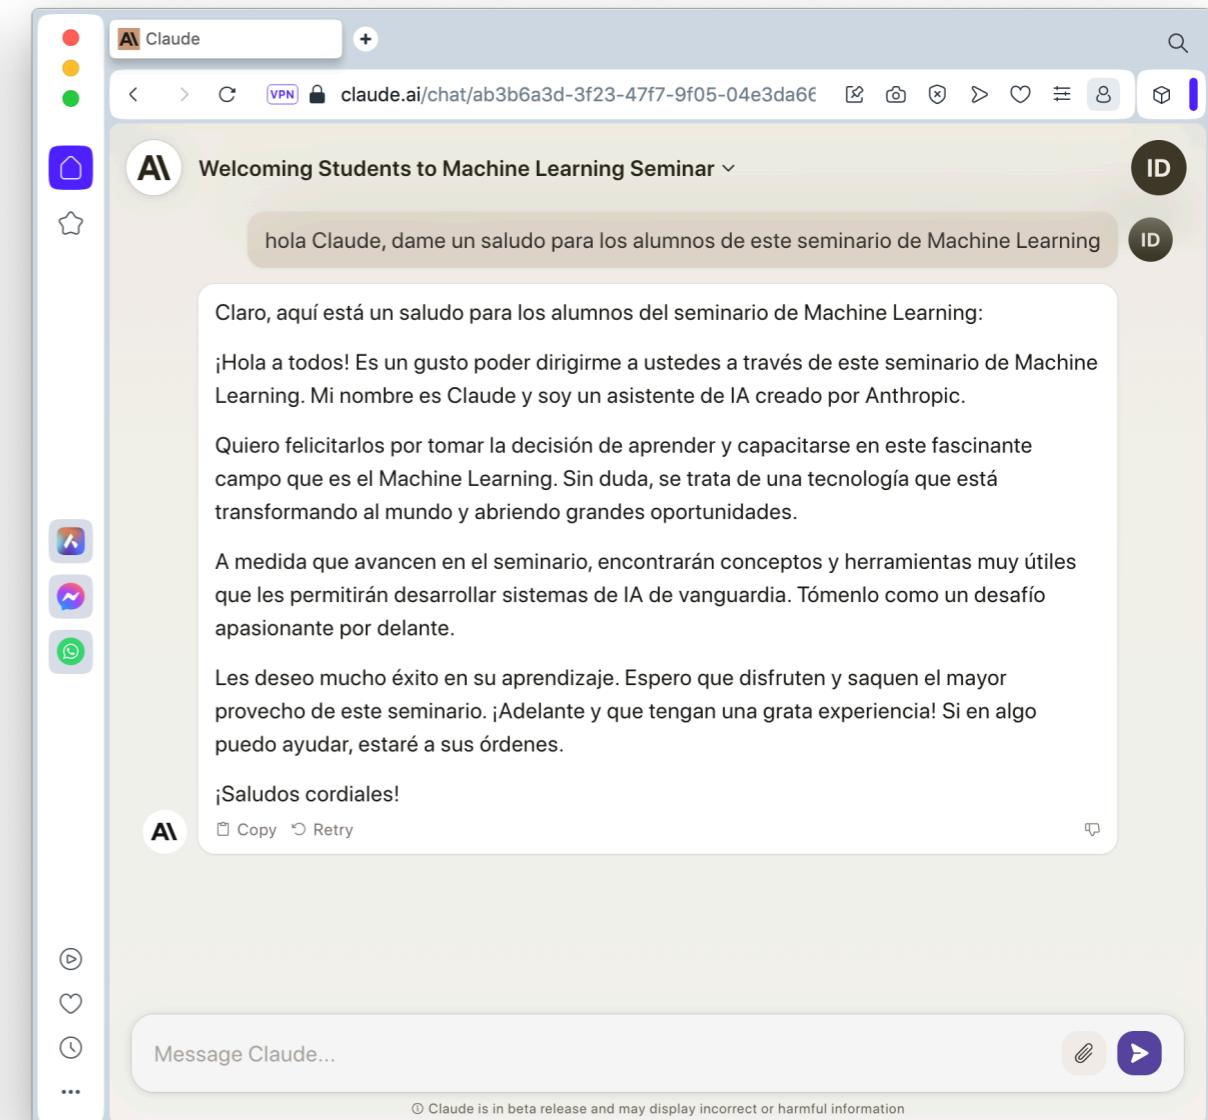
**Upgrade**  
Get GPT-4, DALL-E, and more

**Ignacio Diaz**

**Message ChatGPT...**

ChatGPT can make mistakes. Consider checking important information.

### Claude



**Welcoming Students to Machine Learning Seminar**

hola Claude, dame un saludo para los alumnos de este seminario de Machine Learning

Claro, aquí está un saludo para los alumnos del seminario de Machine Learning:

¡Hola a todos! Es un gusto poder dirigirme a ustedes a través de este seminario de Machine Learning. Mi nombre es Claude y soy un asistente de IA creado por Anthropic.

Quiero felicitarlos por tomar la decisión de aprender y capacitarse en este fascinante campo que es el Machine Learning. Sin duda, se trata de una tecnología que está transformando al mundo y abriendo grandes oportunidades.

A medida que avancen en el seminario, encontrarán conceptos y herramientas muy útiles que les permitirán desarrollar sistemas de IA de vanguardia. Tómenlo como un desafío apasionante por delante.

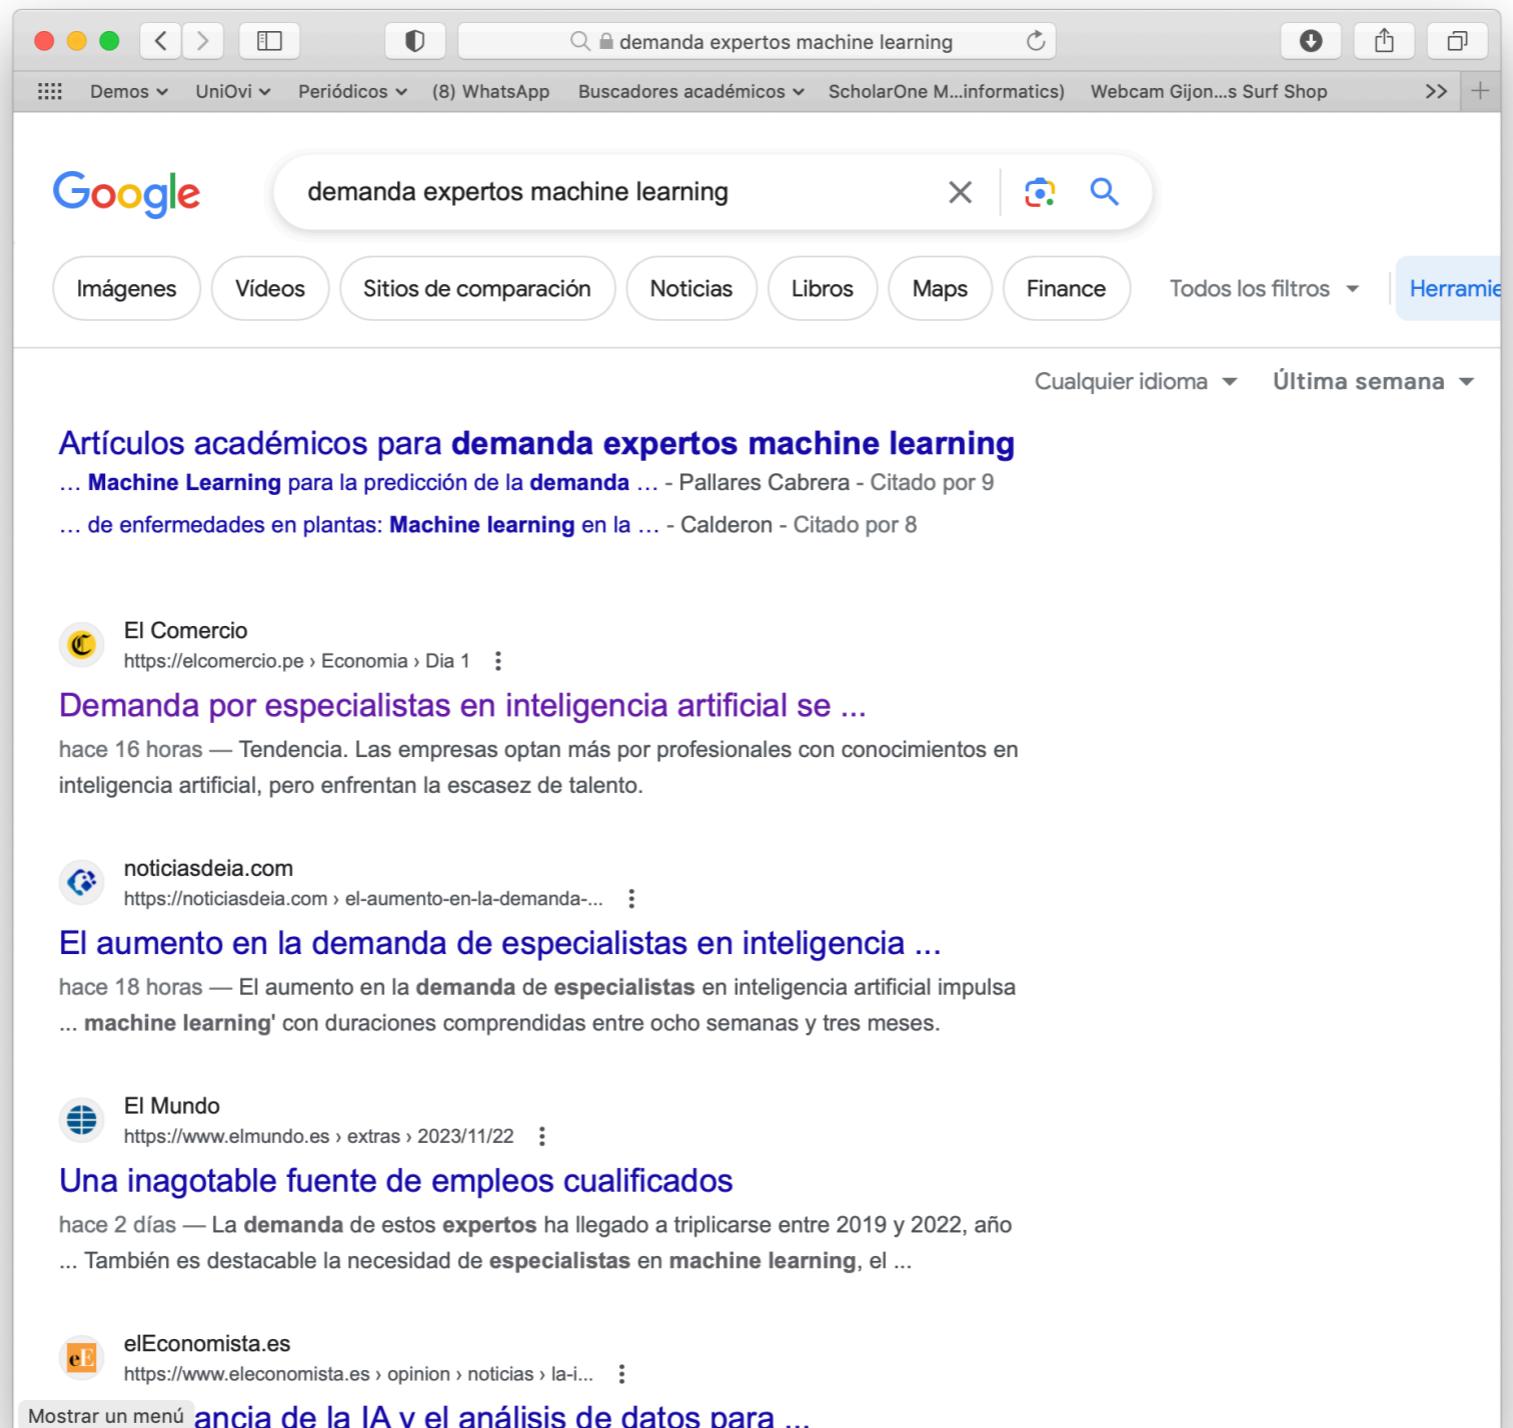
Les deseo mucho éxito en su aprendizaje. Espero que disfruten y saquen el mayor provecho de este seminario. ¡Adelante y que tengan una grata experiencia! Si en algo puedo ayudar, estaré a sus órdenes.

¡Saludos cordiales!

**Message Claude...**

© Claude is in beta release and may display incorrect or harmful information

# Trabajo en deep learning expertos en DL muy demandados ...



Google search results for "demanda expertos machine learning".

Search filters: Imágenes, Videos, Sitios de comparación, Noticias, Libros, Maps, Finance, Todos los filtros, Herramientas.

Language: Cualquier idioma. Date range: Última semana.

**Artículos académicos para demanda expertos machine learning**

- ... Machine Learning para la predicción de la demanda ... - Pallares Cabrera - Citado por 9
- ... de enfermedades en plantas: Machine learning en la ... - Calderon - Citado por 8

**El Comercio**  
<https://elcomercio.pe> › Economía › Dia 1

**Demanda por especialistas en inteligencia artificial se ...**

hace 16 horas — Tendencia. Las empresas optan más por profesionales con conocimientos en inteligencia artificial, pero enfrentan la escasez de talento.

**noticiasdeia.com**  
<https://noticiasdeia.com> › el-aumento-en-la-demanda-...

**El aumento en la demanda de especialistas en inteligencia ...**

hace 18 horas — El aumento en la demanda de especialistas en inteligencia artificial impulsa ... machine learning' con duraciones comprendidas entre ocho semanas y tres meses.

**El Mundo**  
<https://www.elmundo.es> › extras › 2023/11/22

**Una inagotable fuente de empleos cualificados**

hace 2 días — La demanda de estos expertos ha llegado a triplicarse entre 2019 y 2022, año ... También es destacable la necesidad de especialistas en machine learning, el ...

**elEconomista.es**  
<https://www.eleconomista.es> › opinion › noticias › la-i...

Mostrar un menú

ancia de la IA y el análisis de datos para ...

(fecha consulta 24/11/2023)

# ¿Qué son las redes neuronales?

# Breve historia de las RN

## línea de tiempo

	<b>Antecedentes</b>
16xx	1676 regla de la cadena (Leibniz)
	1696 regla de la cadena (L'Hopital)
18xx	1847 optimización descenso gradiente (Cauchy)
1940	<b>Primeros modelos (lineales)</b>
	1943 Mc Culloch & Pitts
	1949 Regla aprendizaje Hebb
1950	<b>"Golden Years" (1956-1974)</b>
	1956 conferencia Dartmouth: nace la IA
1960	★ 1958 Perceptrón lineal (Rosenblatt)
	1960 Adaline (Widrow y Hoff)
	1969 Problema XOR en modelos lineales (Minsky Papert)
1970	<b>"first AI winter" (1974-1980)</b>
1980	<b>"Boom" (1980-1987)</b>
	★ 1980 neocognitrón, primera CNN (Fukushima, 1980)
	1981 aplicación regla cadena a NN (Werbos, 1981)
	1985 backpropagation (LeCun, 1985)
	★ 1985 backpropagation (Parker, 1985)
	1986 backpropagation (Rummelhart et al, 1986)
	1986 representación distribuida (Hinton, 1986)
	1989 Entrenan redes profundas, pero en tiempos inviables
1990	<b>"second AI winter" (1987-1993)</b>
	1995 SVM (Vapnik, 1995)
	★ 1997 LSTM (Hochreiter, Schmidhuber, 1997)
	★ 1998 LeNet, convolucional de 7 capas (LeCun, etc.)
2000	2000 Explosión de trabajos en SVM, SVR
	<b>Deep learning</b>
	★ 2006 Primera red profunda (Hinton, 2006)
	2011 Rectified Linear Units, ReLu (Jarrett et al. 2009)
	2012 AI consigue niveles humanos en reconocimiento
	2013 Google y Facebook entran en DL
	★ 2015 Google libera TensorFlow
	2016 AlphaGo (Deepmind) vence a Lee Sedol
	2017 AlphaGo Zero aprende por refuerzo

★ → hitos relacionados con deep learning

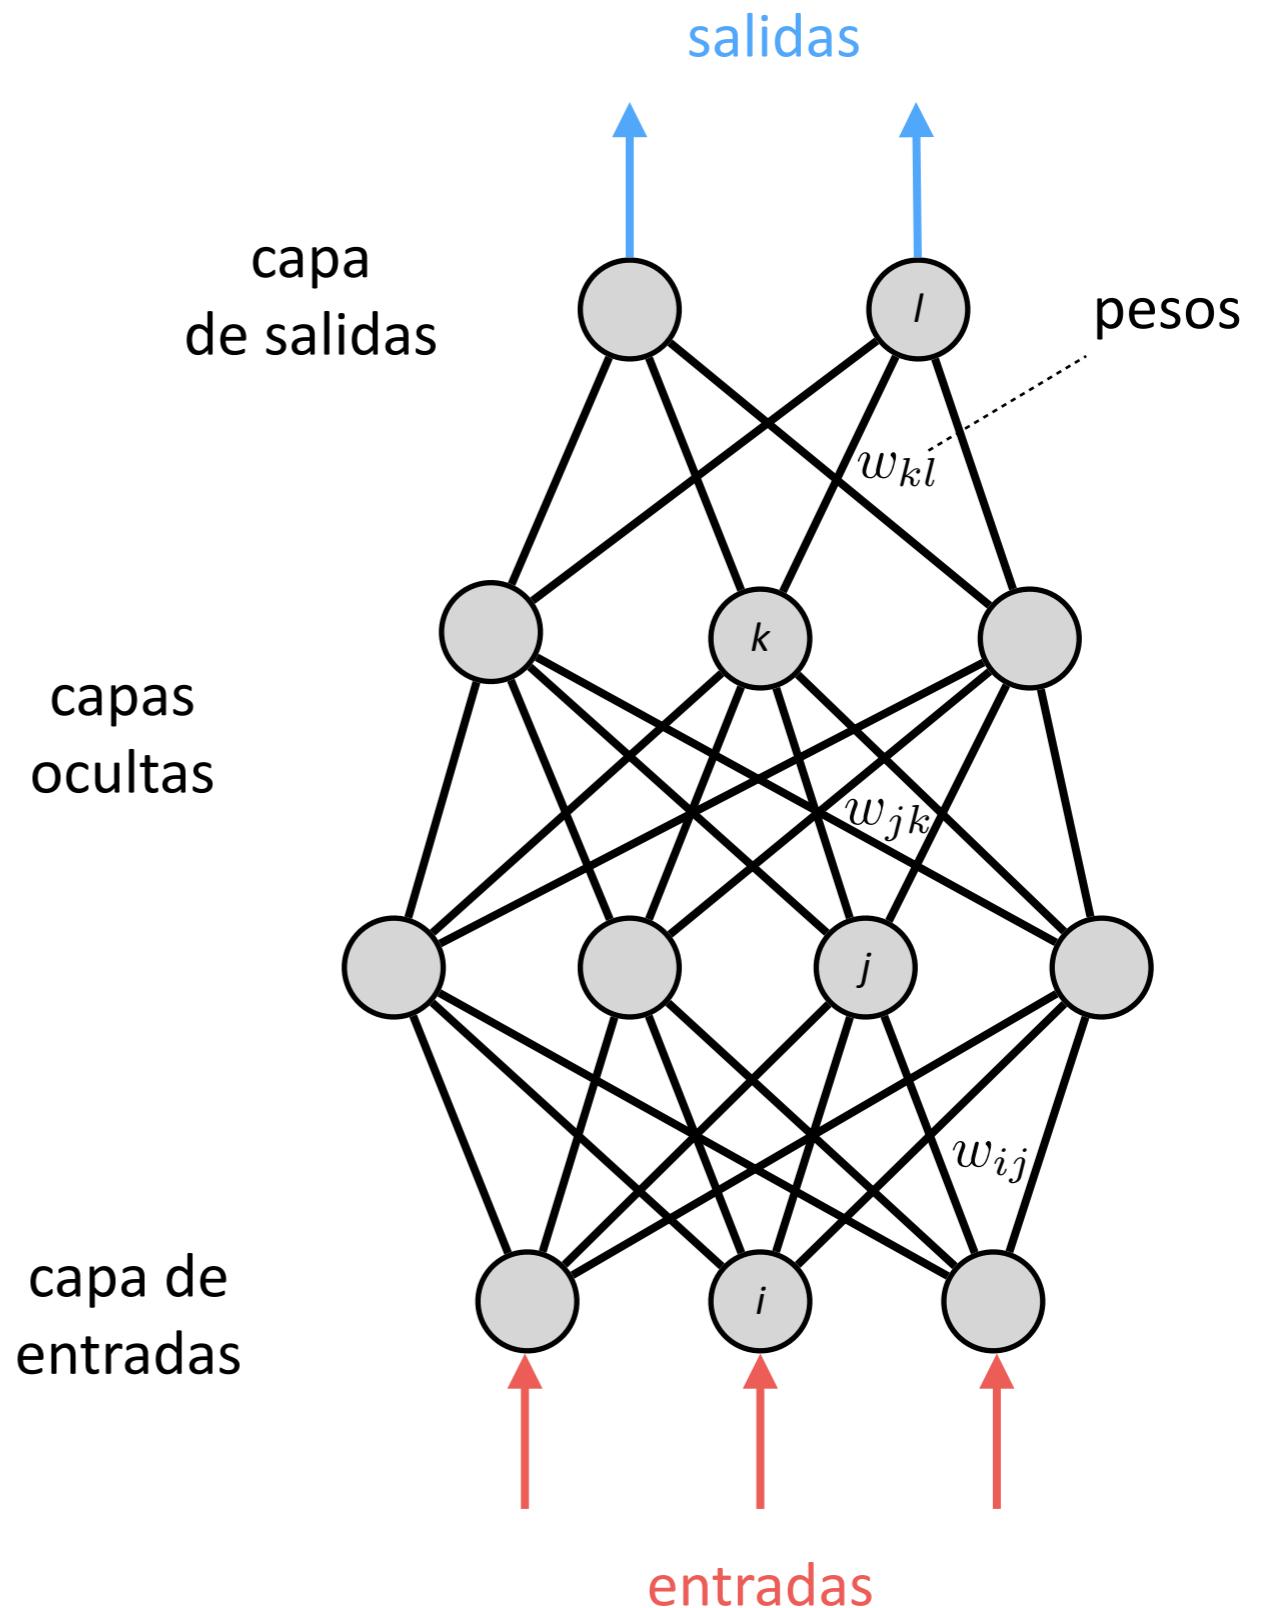
# Redes neuronales

## Arquitectura y elementos

Las RN son algoritmos formados por unidades básicas denominadas **neuronas**

Organizadas en **capas** de varias neuronas

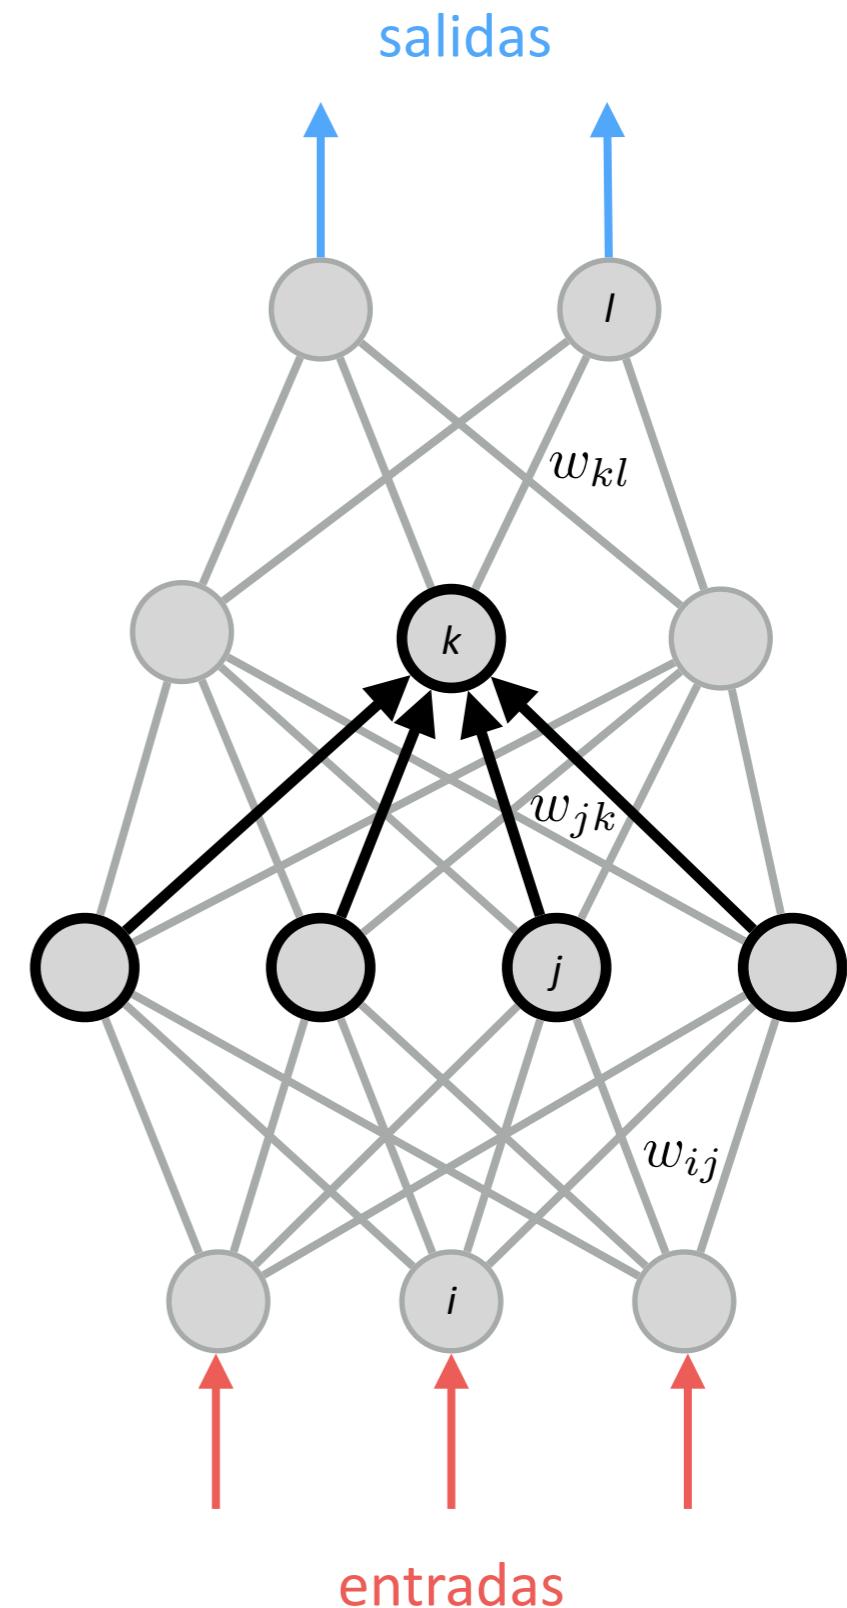
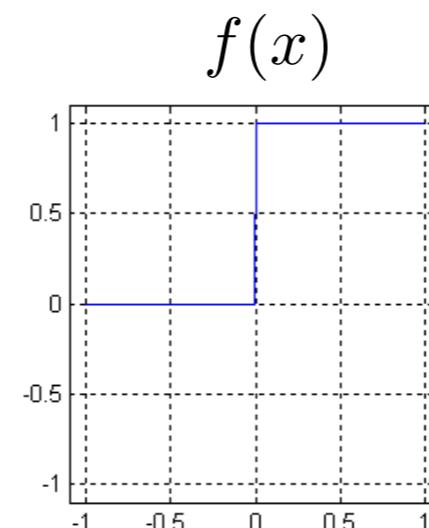
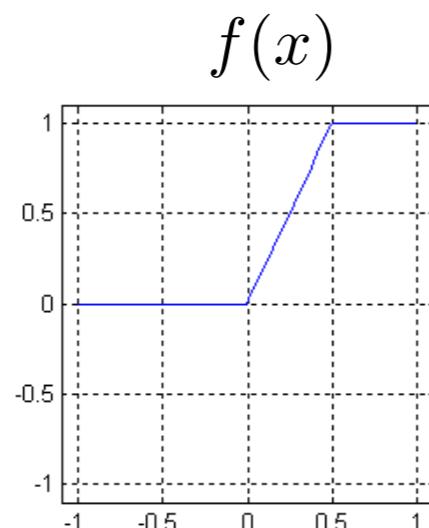
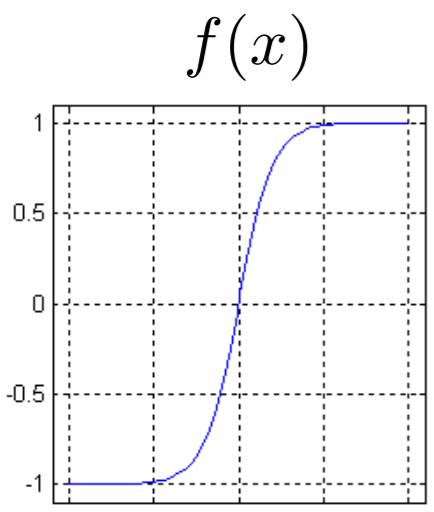
Las salidas de una capa son entradas a la capa siguiente



Cada neurona realiza  
un procesamiento simple no lineal  
(puede ser lineal, como caso particular)

$$a_k = f\left(\sum_j w_{jk} a_j\right)$$

la función de activación  $f$  aporta la no linealidad...



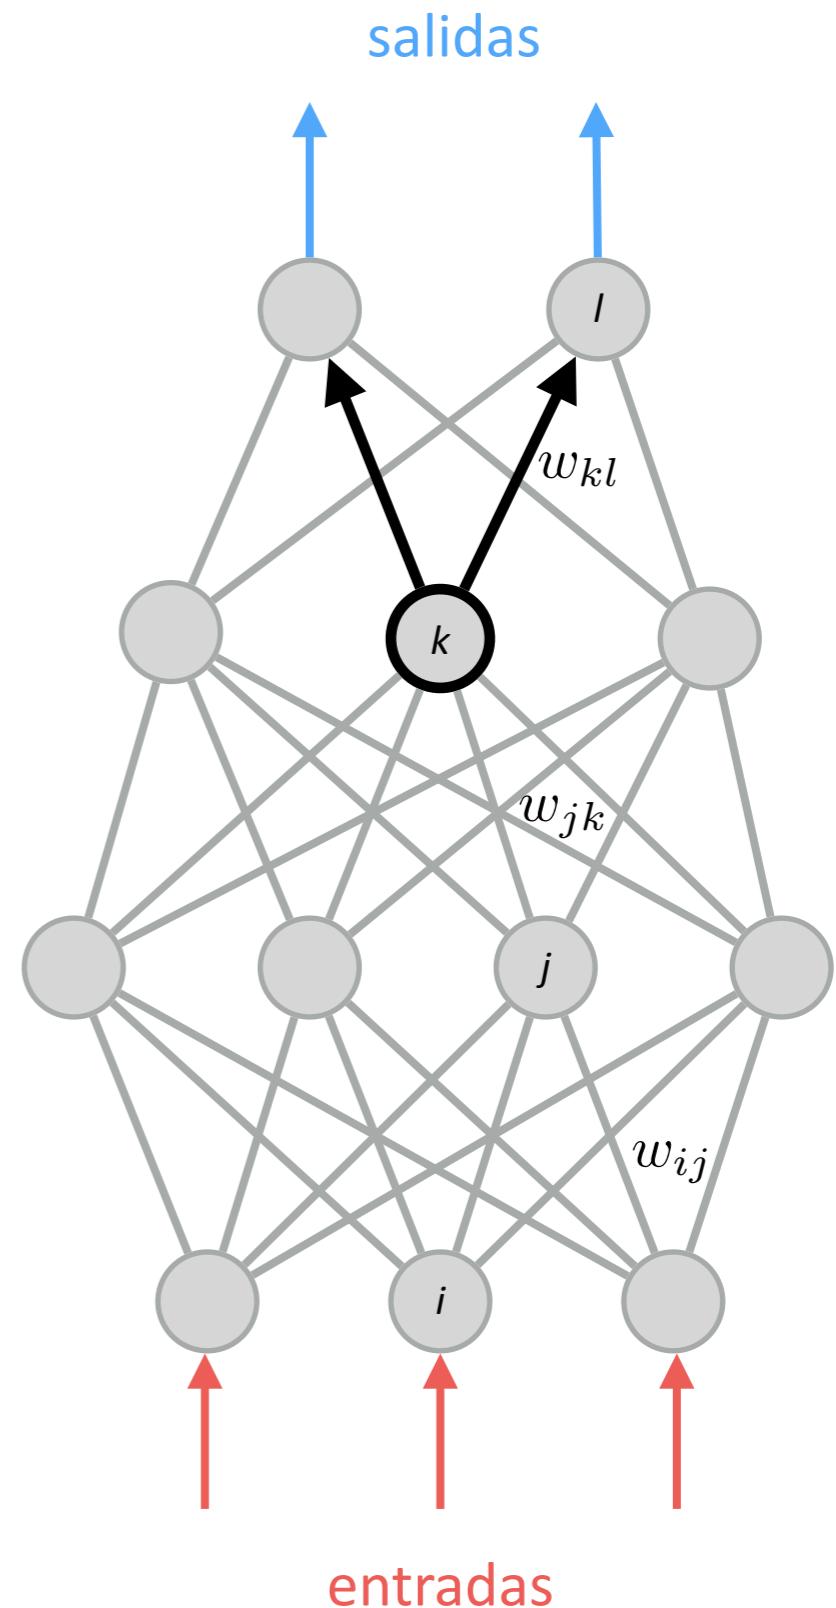
# Redes neuronales

## Arquitectura y elementos

El resultado de cada neurona se transfiere a otras neuronas

... esas neuronas vuelven a realizar el procesamiento descrito

... y así sucesivamente hasta producir una o varias salidas



La red neuronal resulta ser una  
**composición de funciones**

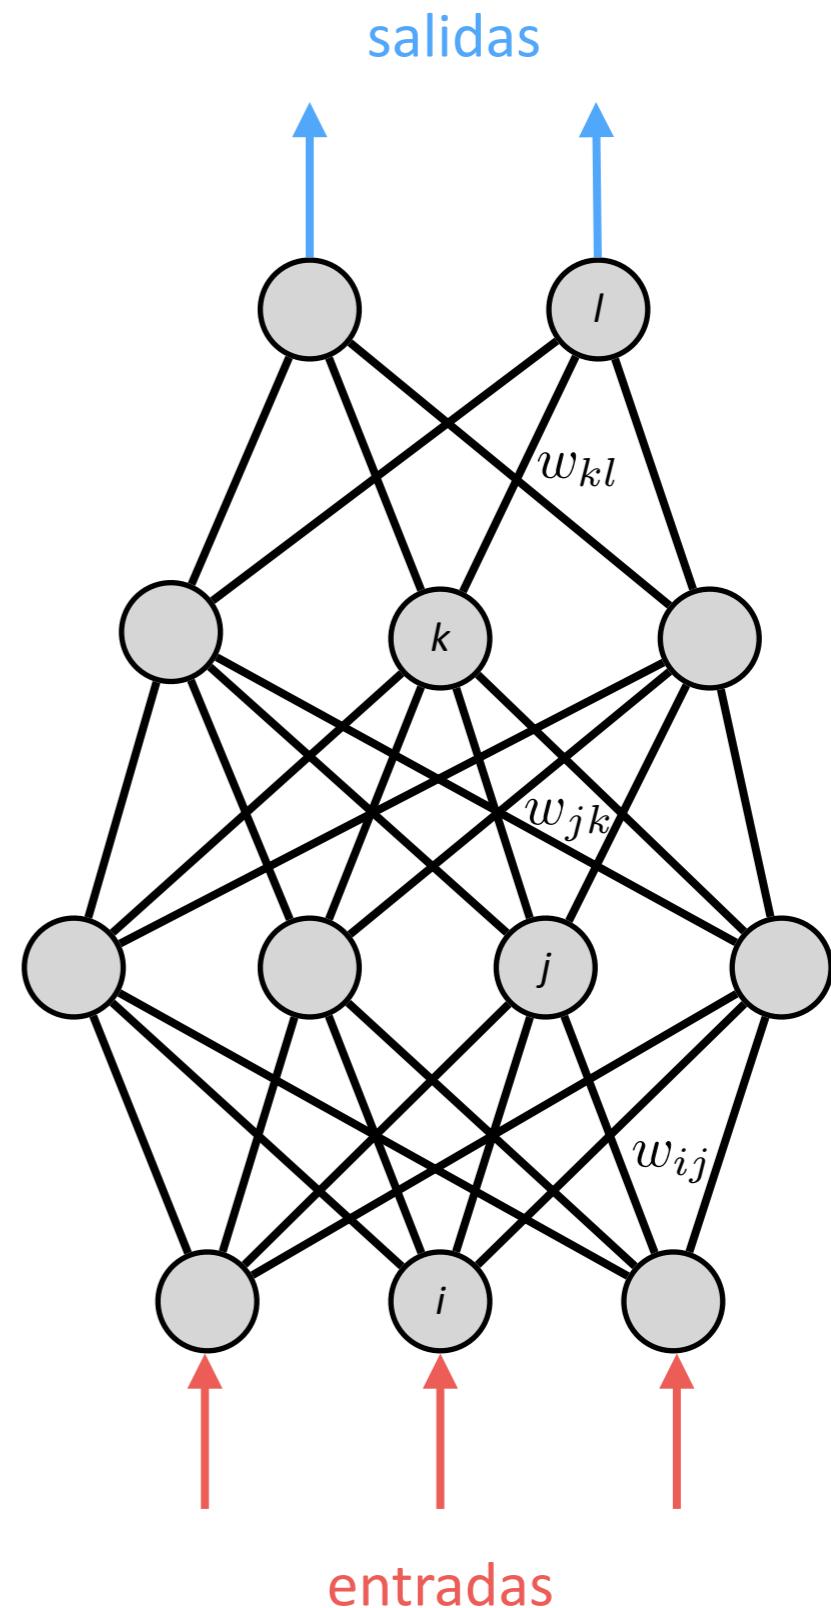
$$a_l = f\left(\sum_k w_{kl} f\left(\sum_j w_{jk} a_j\right)\right)$$

↓

$$a_l = f\left(\sum_k w_{kl} f\left(\sum_j w_{jk} f\left(\sum_j w_{rj} \dots\right)\right)\right)$$

$$\text{salidas} = f(g(h(i(\dots r(\text{entradas}) \dots))))$$

$$\text{salidas} = (f \circ g \circ h \circ i \dots \circ r)(\text{entradas})$$



**La red neuronal resulta ser una composición de funciones**

$$\text{salidas} = f(g(h(i(\dots r(\text{entradas})\dots))))$$



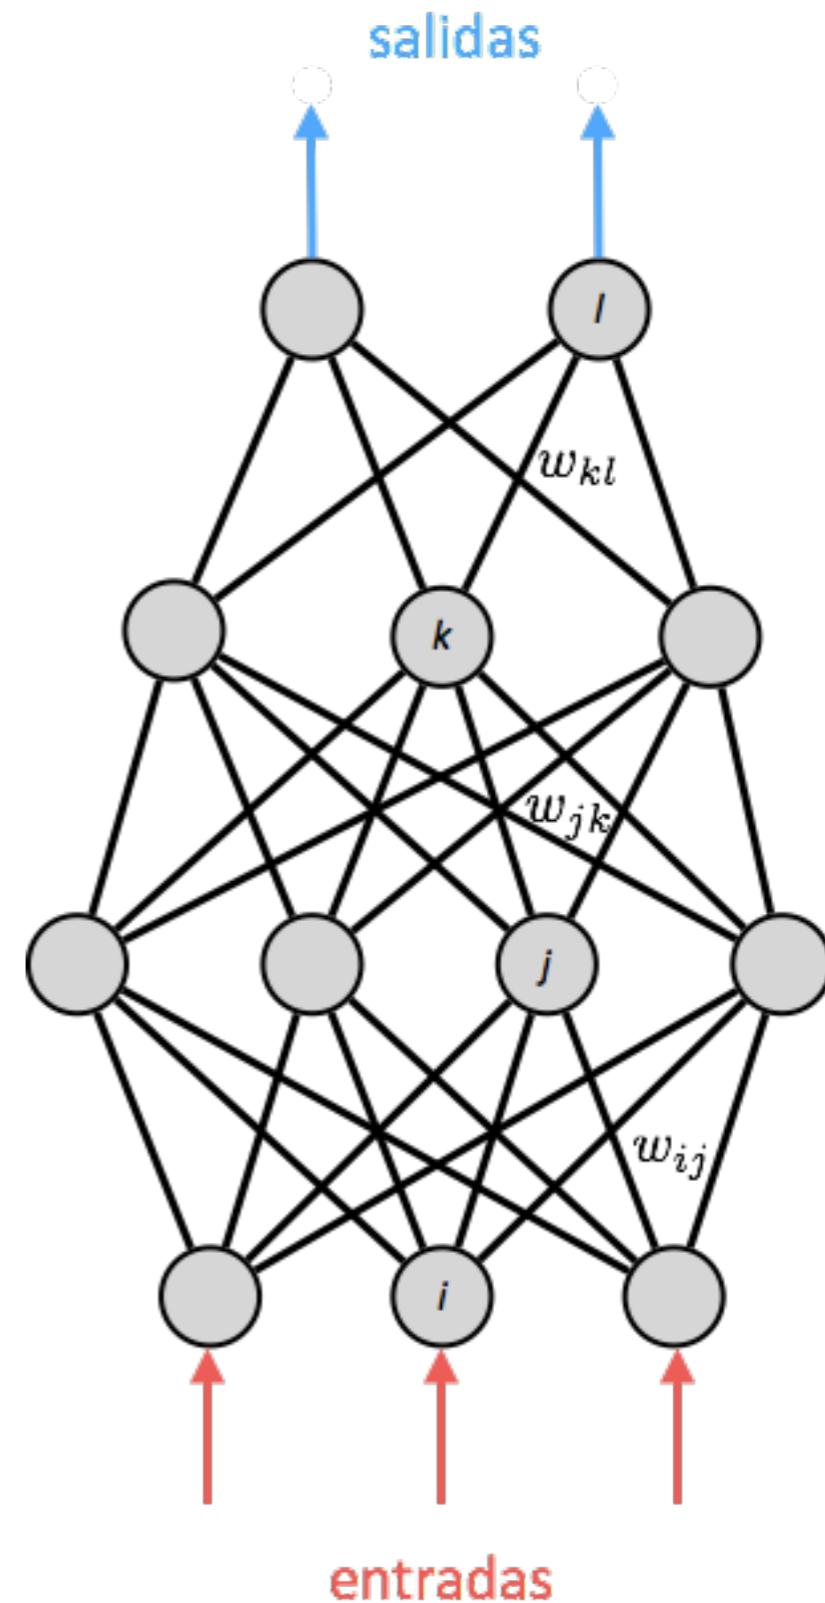
$$\text{salidas} = (f \circ g \circ h \circ i \dots \circ r)(\text{entradas})$$



$$\text{salidas} = F(\text{entradas}, \text{pesos})$$

matemáticamente:

$$\mathbf{y} = F(\mathbf{x}, \mathbf{W})$$



función compleja  
resultante de composición  
de funciones simples

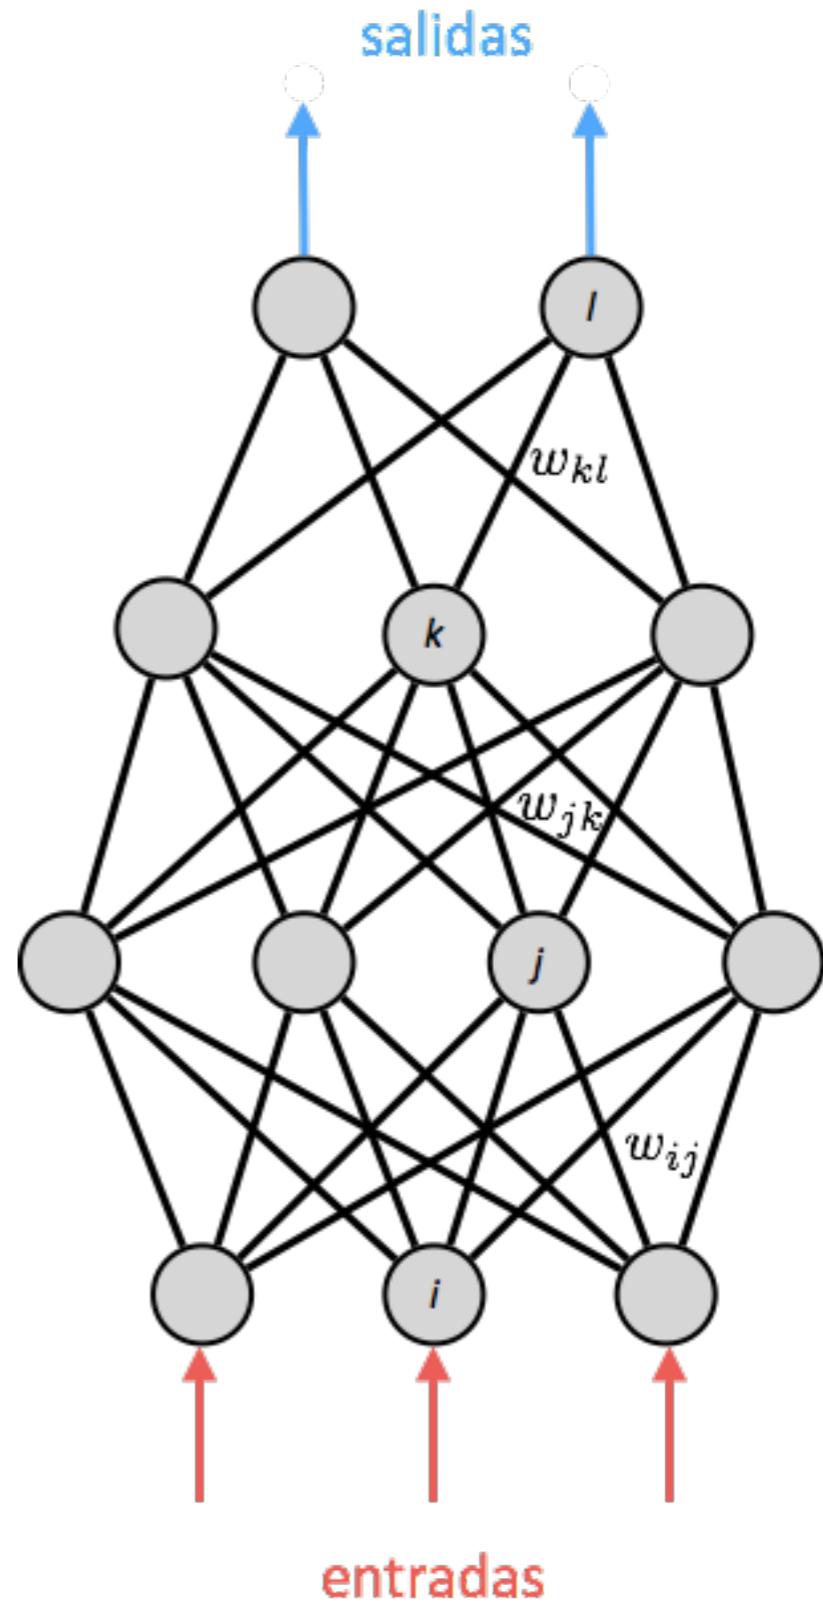
$\downarrow$

$$\mathbf{y} = F(\mathbf{x}, \mathbf{W})$$

$\uparrow$

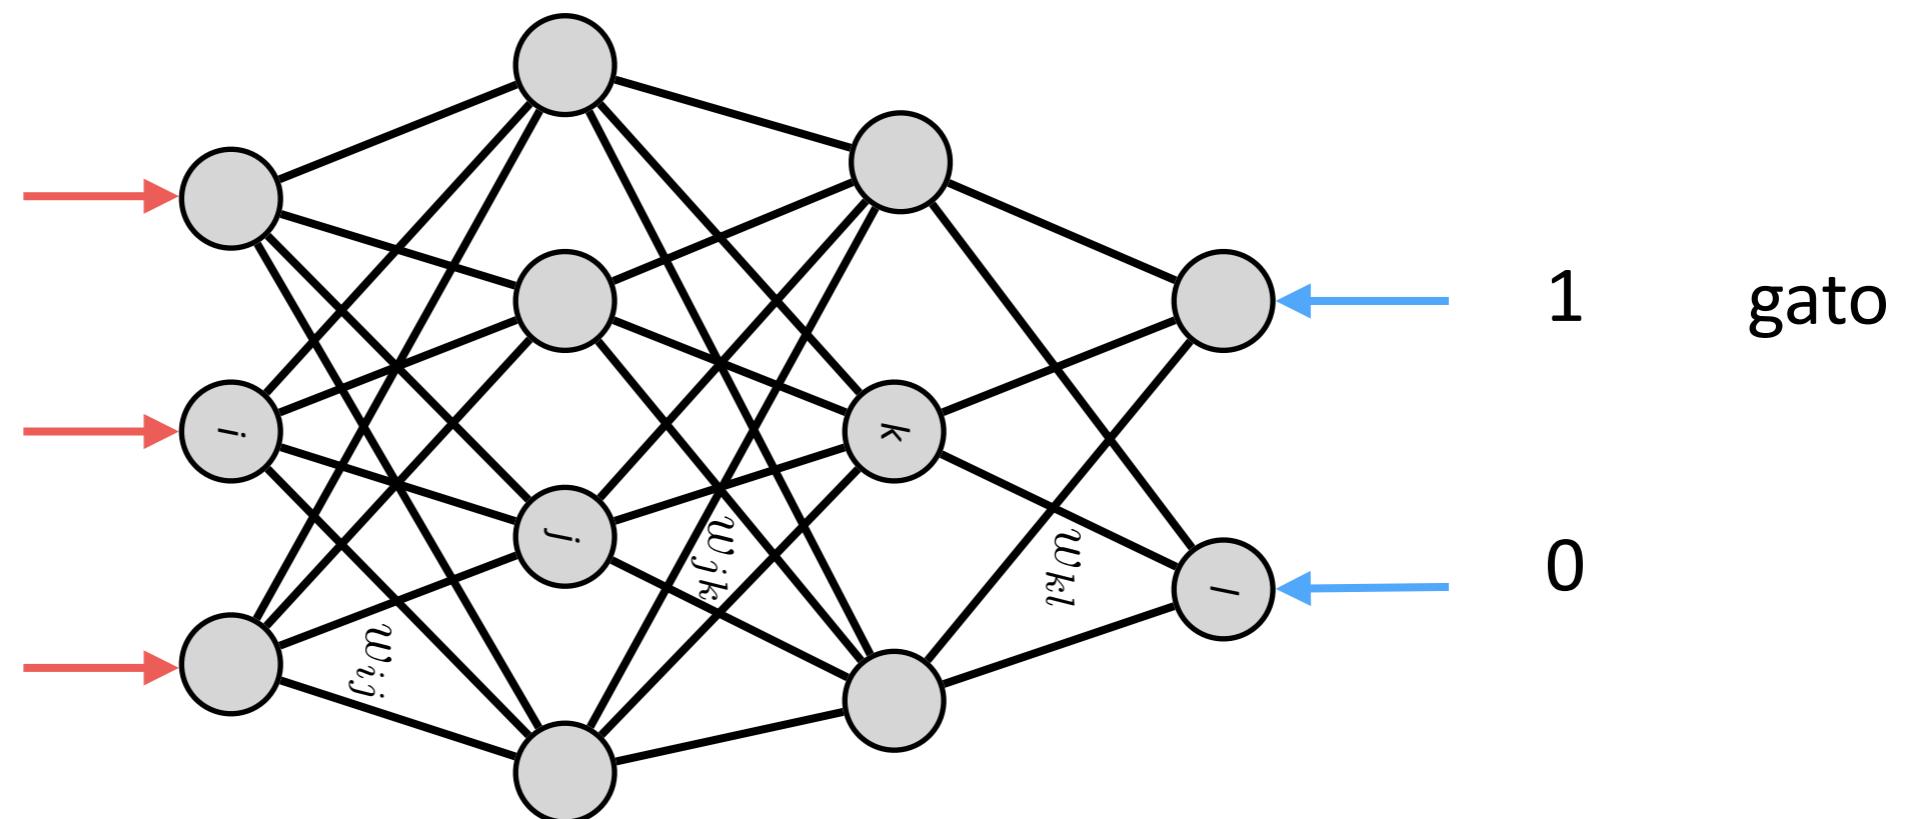
parámetros:  
los pesos de todas  
las neuronas

Los pesos  $\mathbf{W}$   
permiten moldear/ajustar  $F$   
a casi cualquier función

$$\mathbf{y} = f(\mathbf{x})$$


# Aprendizaje a partir de ejemplos

Una RN es capaz de **aprender a partir de ejemplos**  
 ajustando los pesos  $W$  para minimizar un error  
 → problema de optimización



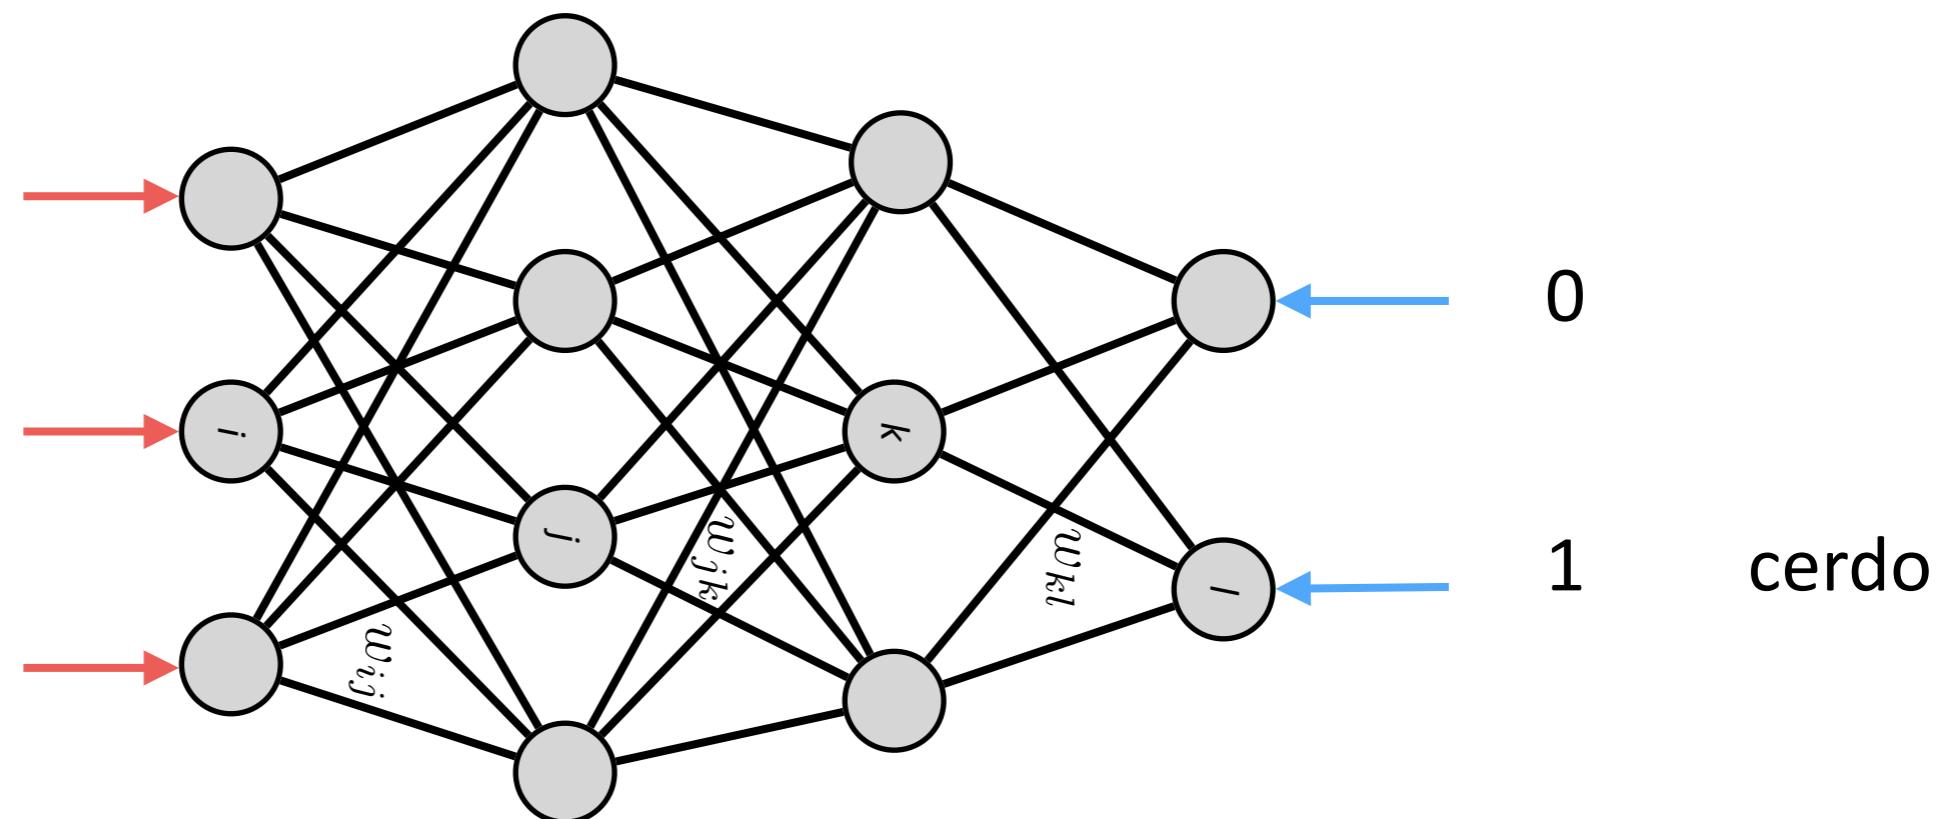
dados  $\{\mathbf{x}_i, \mathbf{y}_i\}$

clasificación:  $\mathbf{y}_i = \{(0, 1), (1, 0), \dots\}$

buscar  $\mathbf{W}$  t.q.  $\sum_i \|\mathbf{y}_i - F(\mathbf{x}_i, \mathbf{W})\|^2$  sea mínimo

regresión/predicción:  $\mathbf{y}_i = \{(5.2, 1.1), (-2.1, 0.2), \dots\}$

Una RN es capaz de **aprender a partir de ejemplos**  
 ajustando los pesos  $W$  para minimizar un error  
 → problema de optimización



dados  $\{\mathbf{x}_i, \mathbf{y}_i\}$

clasificación:  $\mathbf{y}_i = \{(0, 1), (1, 0), \dots\}$

buscar  $\mathbf{W}$  t.q.  $\sum_i \|\mathbf{y}_i - F(\mathbf{x}_i, \mathbf{W})\|^2$  sea mínimo

regresión/predicción:  $\mathbf{y}_i = \{(5.2, 1.1), (-2.1, 0.2), \dots\}$

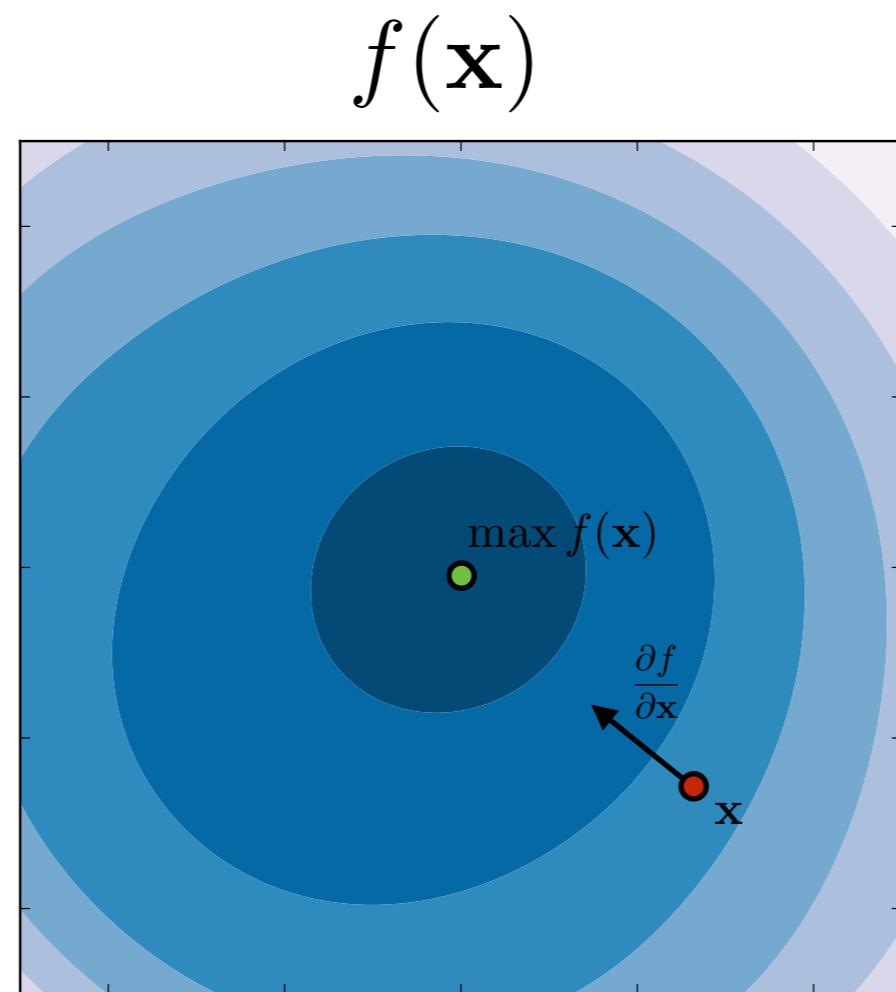
# Backpropagation

aprendizaje por “retropropagación” del error

El gradiente de una función  $f()$   
de varias variables

$$\nabla f(x_1, x_2, \dots, x_n) = \frac{\partial f}{\partial \mathbf{x}}$$

es un **vector** en la dirección  
de máximo crecimiento de  $f$

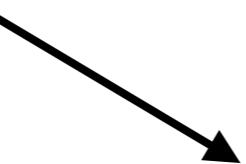


# Backpropagation

aprendizaje por “retropropagación” del error

Si definimos el error de una RN como

$$E = \sum_i \|y_i - F(x_i, W)\|^2$$



dado que  $y_i$ ,  $x_i$ , son conocidos y fijos  
(son los ejemplos) tenemos que

$$E = E(W)$$



¡El gradiente del error

$$\nabla E = \frac{\partial E}{\partial W}$$

nos dice en qué dirección  
debemos mover los pesos  
para disminuir el error!

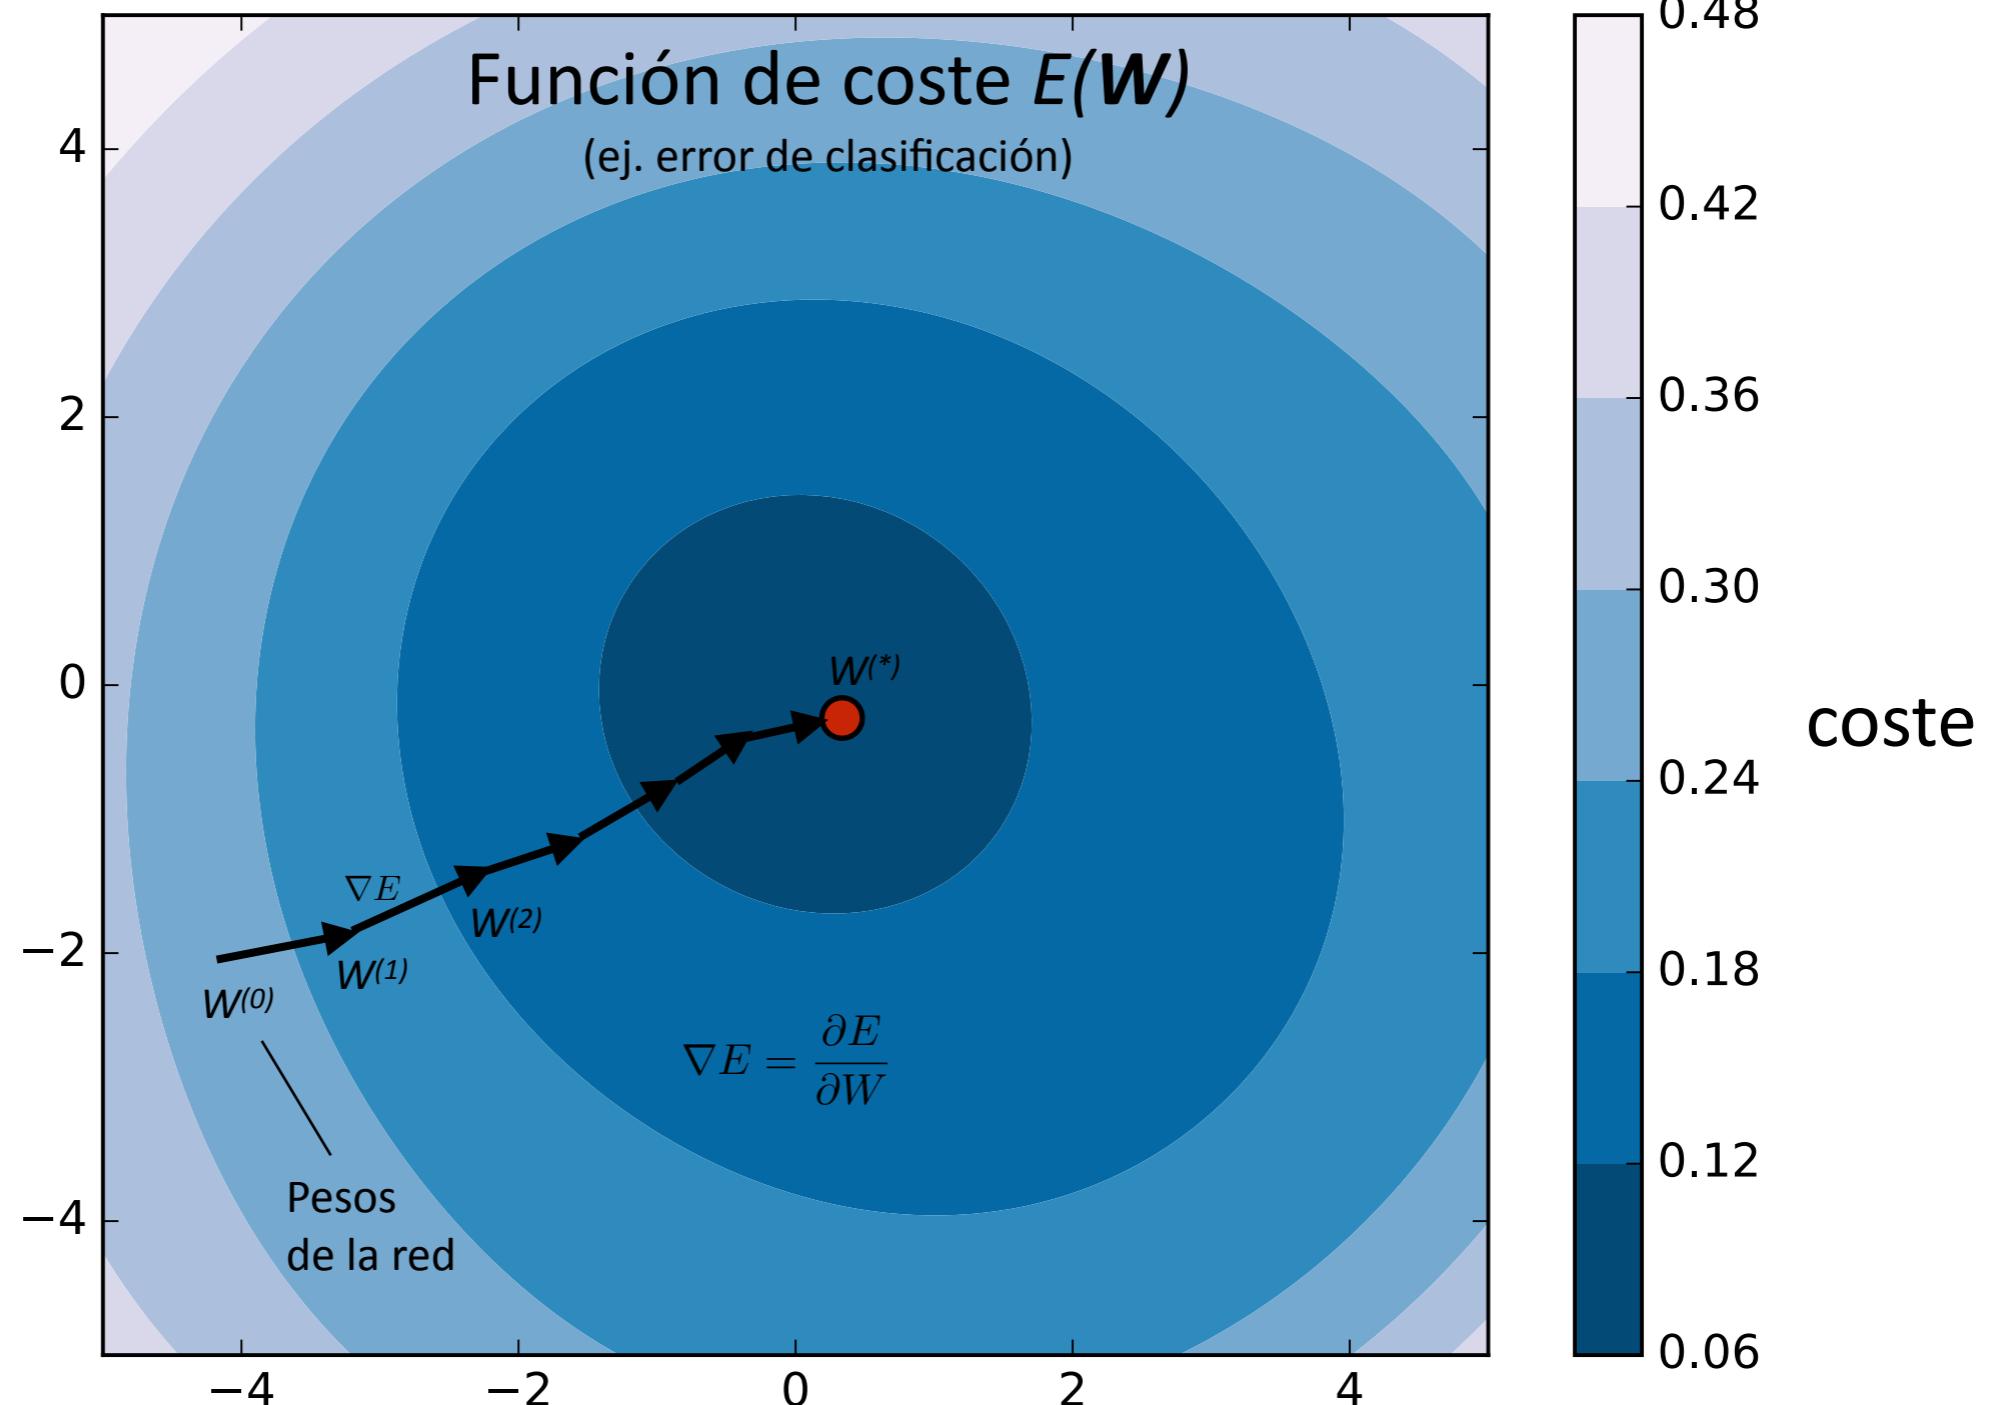


$$W^{(k)} \leftarrow W^{(k-1)} - \mu \frac{\partial E}{\partial W}$$

Método  
“gradient descent”

# Backpropagation

## Descenso del gradiente



# Backpropagation

## aprendizaje por “retropropagación” del error

**Cuestión fundamental del aprendizaje**  
**Determinar el gradiente del error**  
**a partir de los ejemplos**

conocidos los ejemplos  $x_i, y_i$   
y los pesos actuales  $\mathbf{W}$



determinar  
el gradiente  
que nos dice hacia  
dónde mover los pesos

$$\nabla E = \frac{\partial E}{\partial \mathbf{W}}$$

todo indica que va a haber que derivar



# Backpropagation

## aprendizaje por “retropropagación” del error

Backpropagation es el mecanismo en el que se basa el aprendizaje profundo. Data de los años 80.

Las RN son, básicamente  
**composiciones de funciones**

↓

**regla de la cadena**  
aplicada masivamente

↓

ajusta pesos  
en orden inverso a la ejecución  
a partir de la diferencia entre la salida real y la  
deseada

(Rumelhart, Hinton and Williams, 1986)

NATURE VOL. 323 9 OCTOBER 1986 LETTERS TO NATURE 533

**Learning representations by back-propagating errors**

David E. Rumelhart\*, Geoffrey E. Hinton† & Ronald J. Williams\*

\* Institute for Cognitive Science, C-015, University of California, San Diego, La Jolla, California 92093, USA  
† Department of Computer Science, Carnegie-Mellon University, Pittsburgh, Philadelphia 15213, USA

We describe a new learning procedure, back-propagation, for networks of neurone-like units. The procedure repeatedly adjusts the weights of the connections in the network so as to minimize a measure of the difference between the actual output vector of the net and the desired output vector. As a result of the weight adjustments, internal ‘hidden’ units which are not part of the input or output come to represent important features of the task domain, and the regularities in the task are captured by the interactions of these units. The ability to create useful new features distinguishes back-propagation from earlier, simpler methods such as the perceptron-convergence procedure<sup>1</sup>. There have been many attempts to design self-organizing neural networks. The aim is to find a powerful synaptic modification rule that will allow an arbitrarily connected neural network to develop an internal structure that is appropriate for a particular task domain. The task is specified by giving the desired state vector of the output units for each state vector of the input units. If the input units are directly connected to the output units it is relatively easy to find learning rules that iteratively adjust the relative strengths of the connections so as to progressively reduce the difference between the actual and desired output vectors<sup>2</sup>. Learning becomes more interesting but more difficult when we introduce hidden units whose actual or desired states are not specified by the task. (In perceptrons, there are ‘feature analysers’ between the input and output that are not true hidden units because their input connections are fixed by hand, so their states are completely determined by the input vector: they do not learn representations.) The learning procedure must decide under what circumstances the hidden units should be active in order to help achieve the desired input-output behaviour. This amounts to deciding what these units should represent. We demonstrate that a general purpose and relatively simple procedure is powerful enough to construct appropriate internal representations.

The simplest form of the learning procedure is for layered networks which have a layer of input units at the bottom; any number of intermediate layers; and a layer of output units at the top. Connections within a layer or from higher to lower layers are forbidden, but connections can skip intermediate layers. An input vector is presented to the network by setting the states of the input units. Then the states of the units in each layer are determined by applying equations (1) and (2) to the connections coming from lower layers. All units within a layer have their states set in parallel, but different layers have their states set sequentially, starting at the bottom and working upwards until the states of the output units are determined.

The total input,  $x_j$ , to unit  $j$  is a linear function of the outputs,  $y_i$ , of the units that are connected to  $j$  and of the weights,  $w_{ji}$ , on these connections

$$x_j = \sum_i y_i w_{ji} \quad (1)$$

Units can be given biases by introducing an extra input to each unit which always has a value of 1. The weight on this extra input is called the bias and is equivalent to a threshold of the opposite sign. It can be treated just like the other weights.

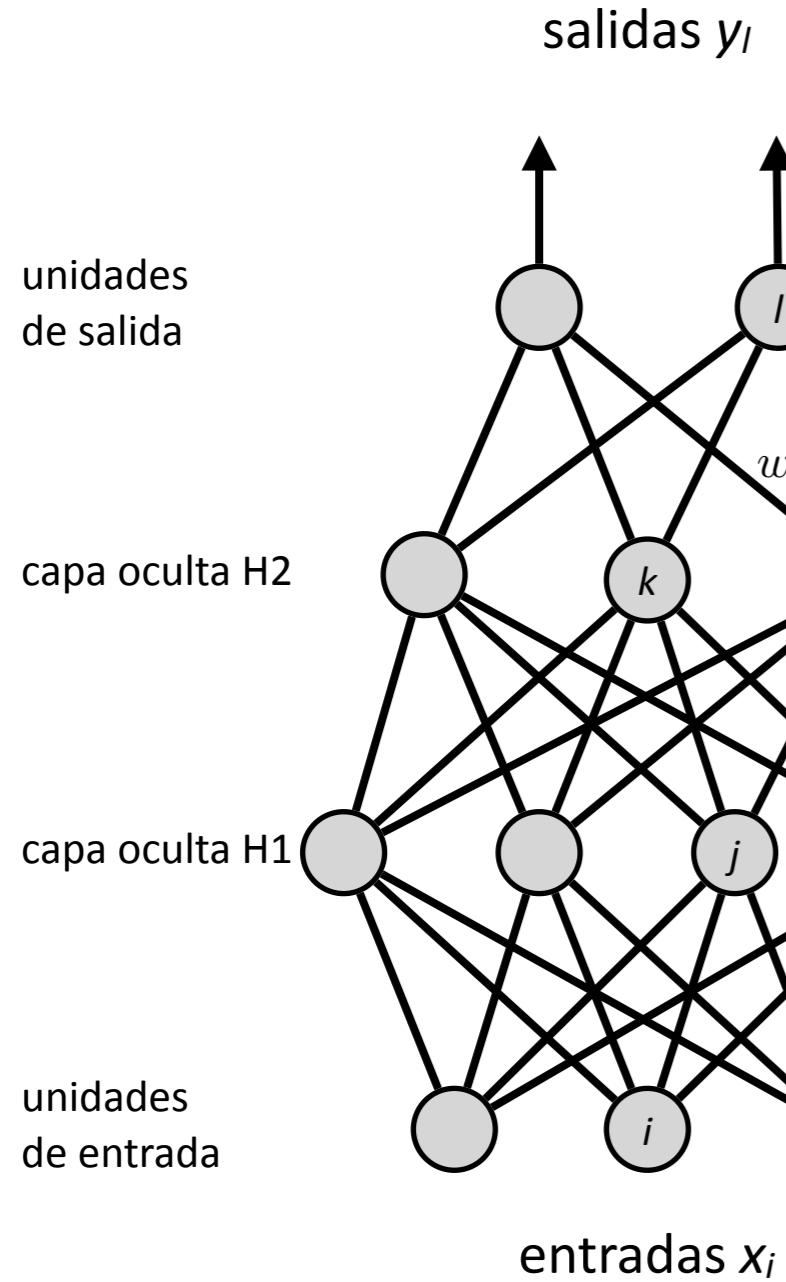
A unit has a real-valued output,  $y_j$ , which is a non-linear function of its total input

$$y_j = \frac{1}{1 + e^{-x_j}} \quad (2)$$

<sup>1</sup> To whom correspondence should be addressed

# Backpropagation

aprendizaje por “retropropagación” del error



$$y_l = f(z_l)$$

$$z_l = \sum_{k \in H2} w_{kl} y_k$$

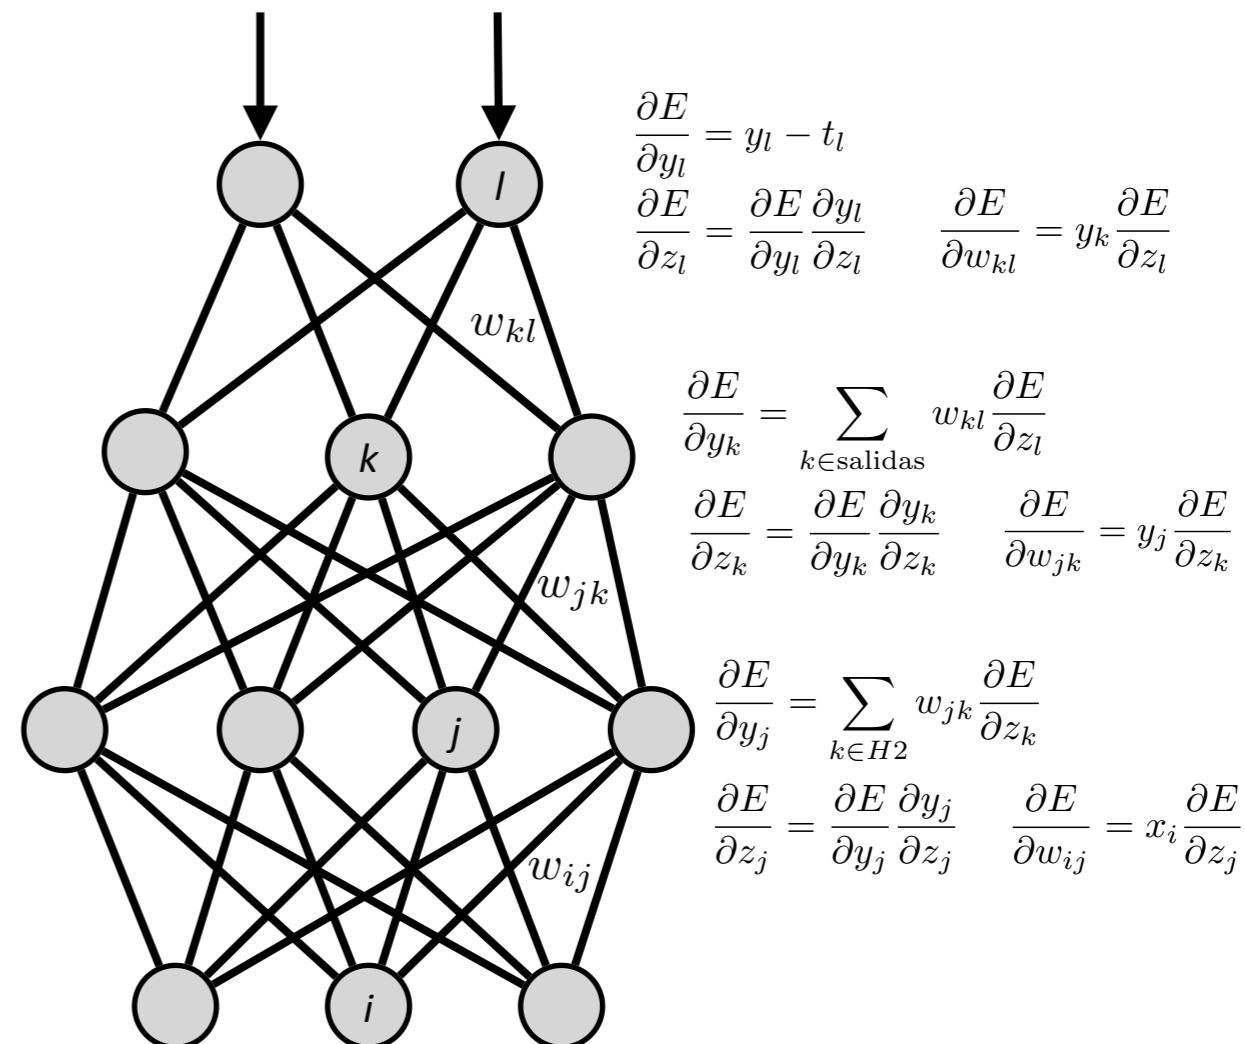
$$y_k = f(z_k)$$

$$z_k = \sum_{j \in H1} w_{jk} y_j$$

$$y_j = f(z_j)$$

$$z_j = \sum_{i \in \text{entrada}} w_{ij} x_i$$

Comparar salidas  $y_l$   
con objetivos  $t_l$



Forward pass

Backward pass

# Backpropagation

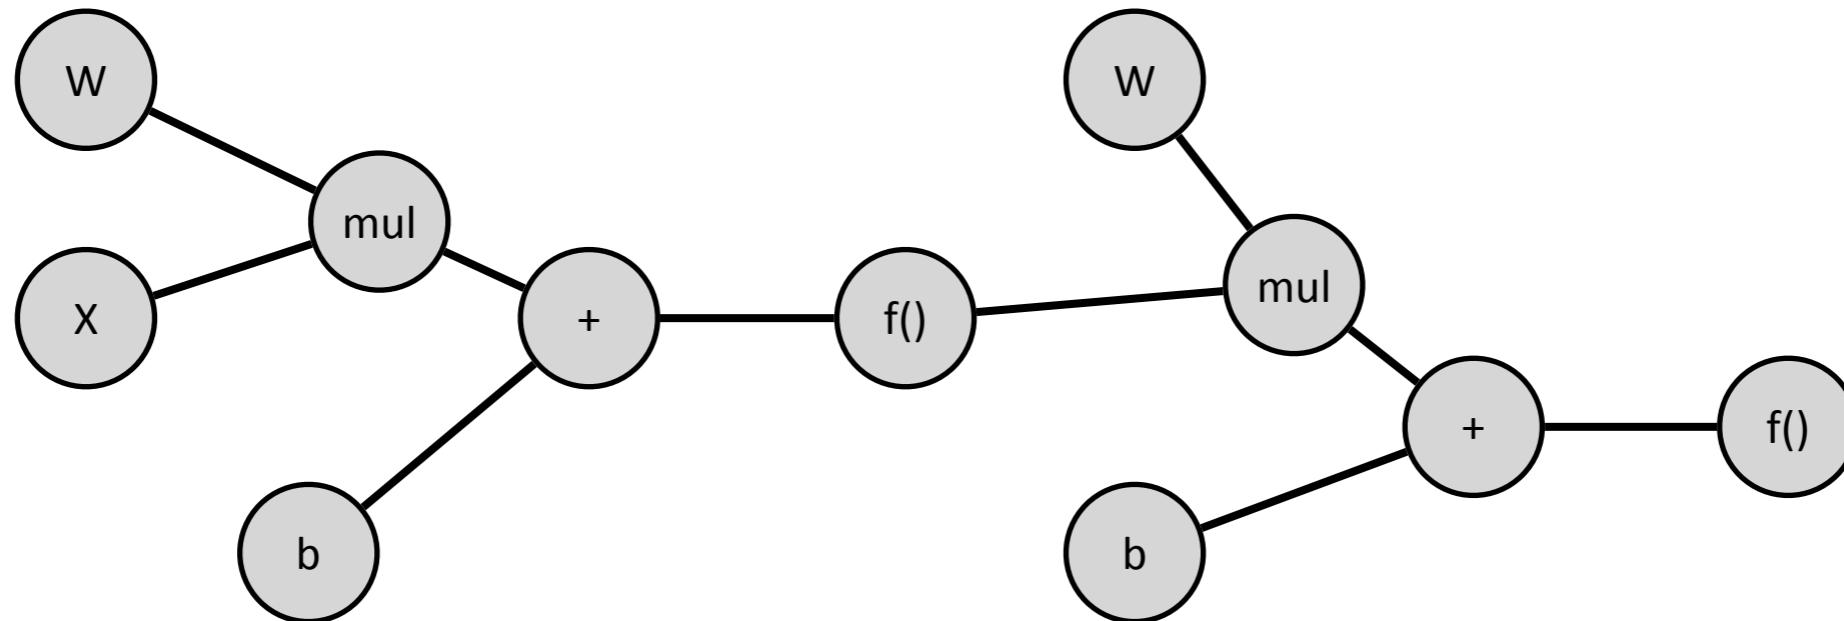
## aprendizaje por “retropropagación” del error

¿ tengo que hacer todo eso ?

las librerías para deep learning



permiten definir la RN como “grafo” de funciones



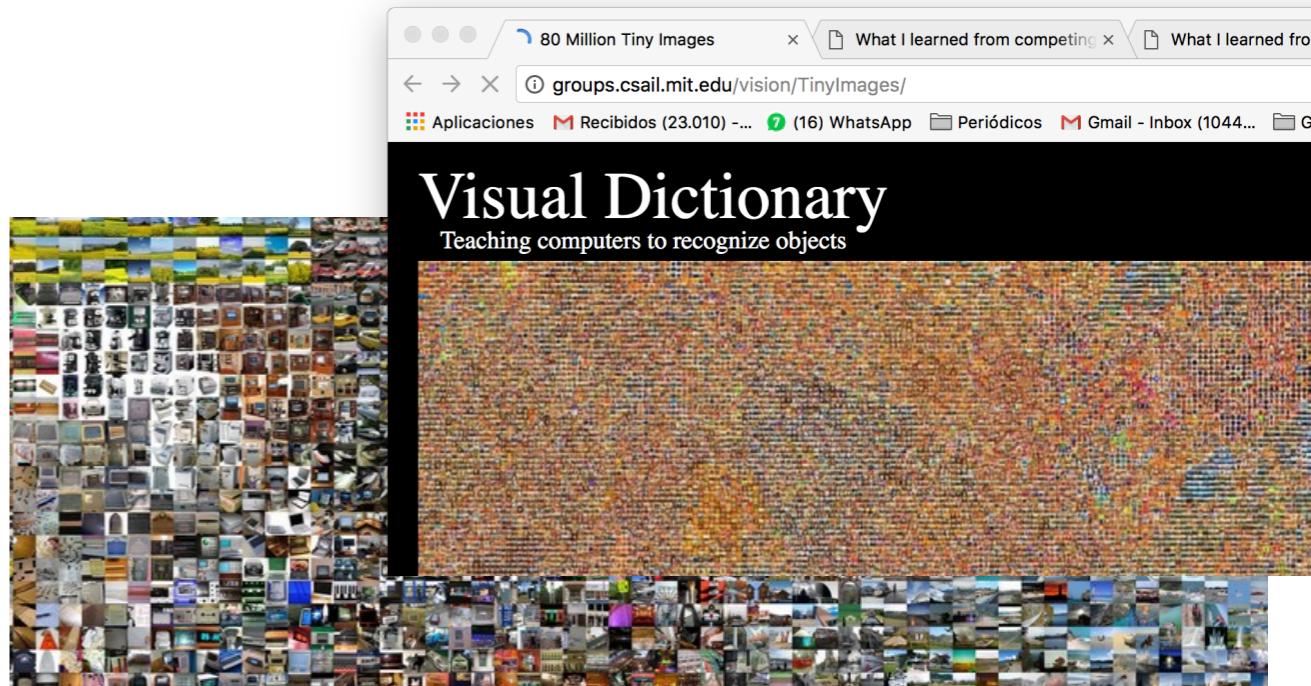
y calcular el gradiente de los pesos  
respecto a una función de coste (“loss function”)

hasta aquí las redes neuronales convencionales...  
... pero  
¿qué es el deep learning?

## Abundancia de datos

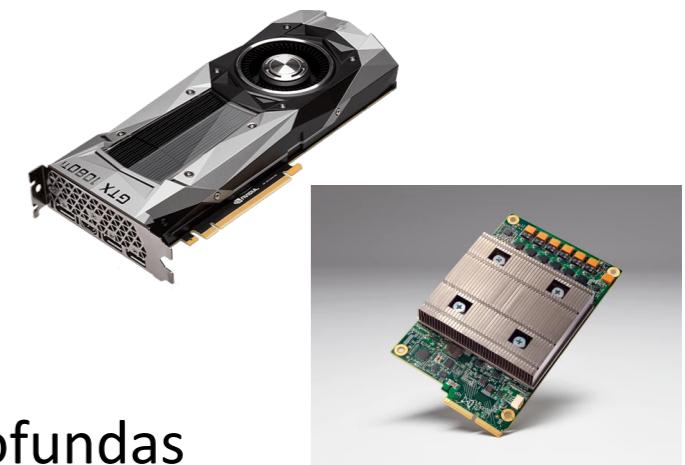
no necesitamos tanto generalizar

- CIFAR10 (60.000, 32x32, 10 clases)
- imageNet (>14M imágenes etiquetadas)
- Tiny Images



## Avances en computación

- disponibilidad de CPU's más potentes
- hardware gráfico → GPU's
- hardware específico → TPU's (*tensor processing units*)



## Mejoras en los algoritmos

- cross-entropy → clasificación
- ReLU (rectifier Linear Units) → vanishing gradient → redes profundas
- convolucionales y pooling → imágenes, audio
- redes recurrentes (LSTM) → secuencias, memoria, lenguaje

## Liberación de librerías de deep learning



## Inteligencia Artificial (IA)

*replicación de la inteligencia humana  
en los computadores*

## Machine Learning (ML)

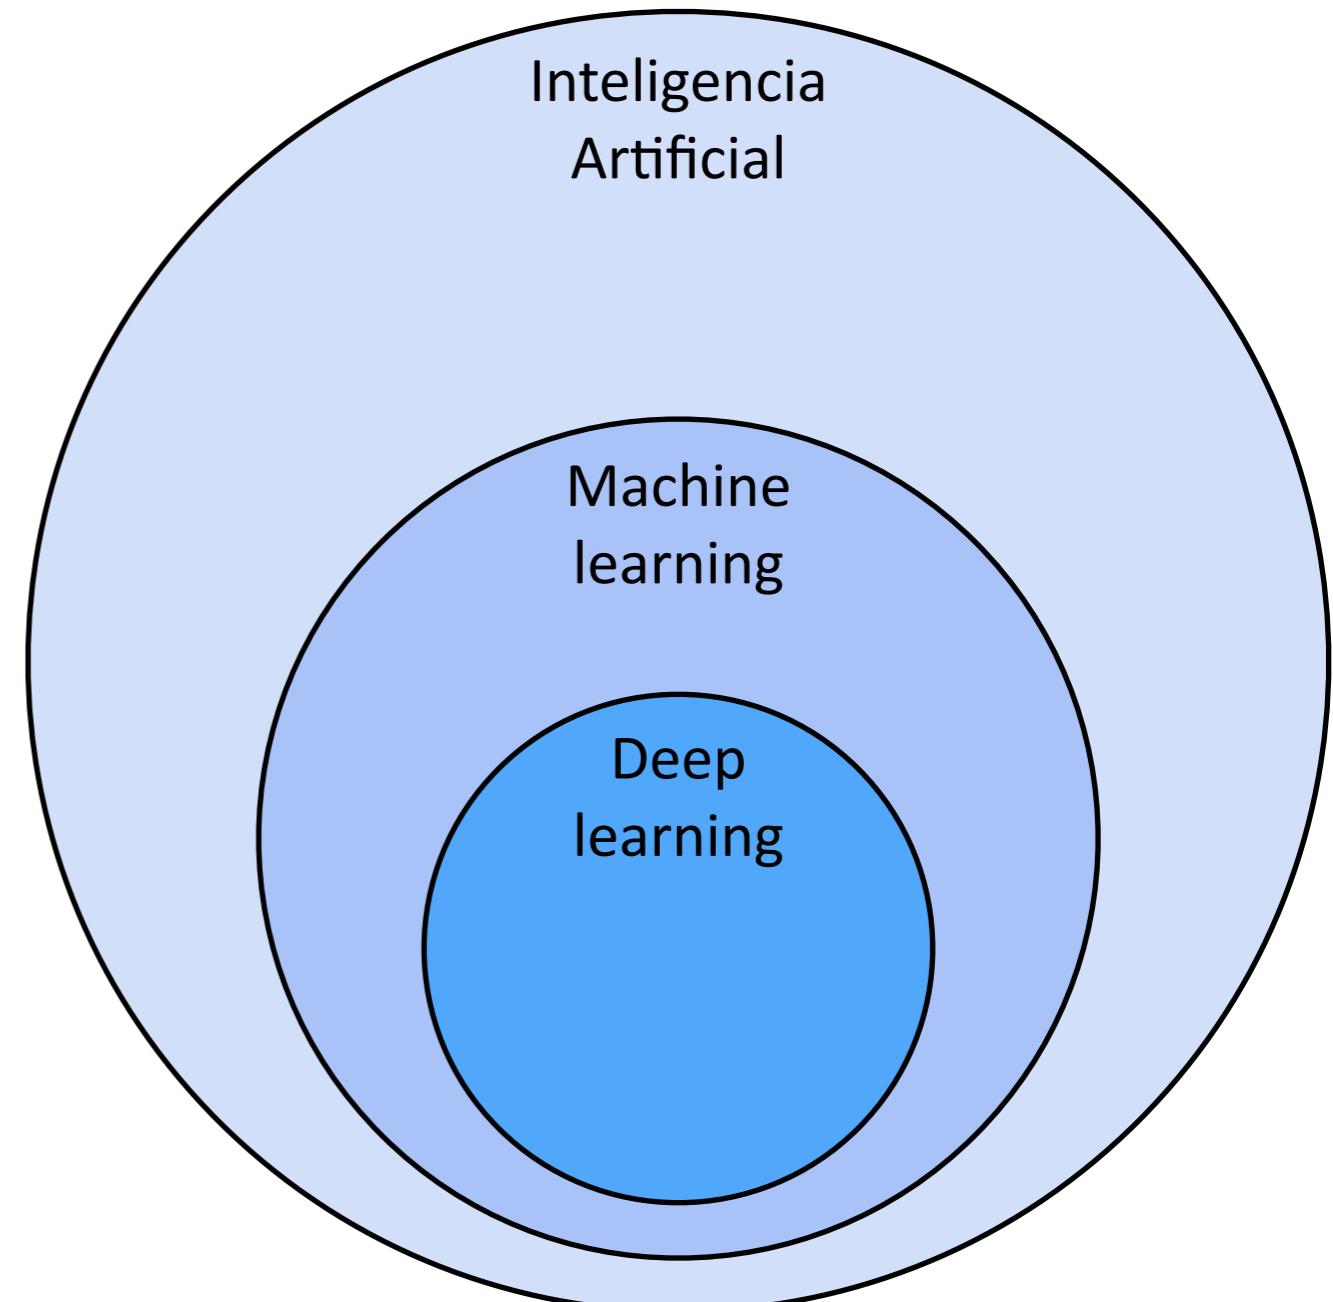
(aprendizaje máquina)

*habilidad de una máquina para aprender  
a partir de conjuntos de datos  
en lugar de a partir de reglas fijas*

## Deep Learning (DL)

(aprendizaje profundo)

*implica un aprendizaje a partir de ejemplos  
utilizando redes neuronales  
con muchas capas*



# ¿qué caracteriza al deep learning (DL)?

muchas capas, muchas neuronas, muchos pesos ...

DL utiliza **redes neuronales** con muchos **niveles** (capas), organizados **jerárquicamente**

muchas capas  
muchas neuronas en cada capa  
 $\sim 10^6$  pesos

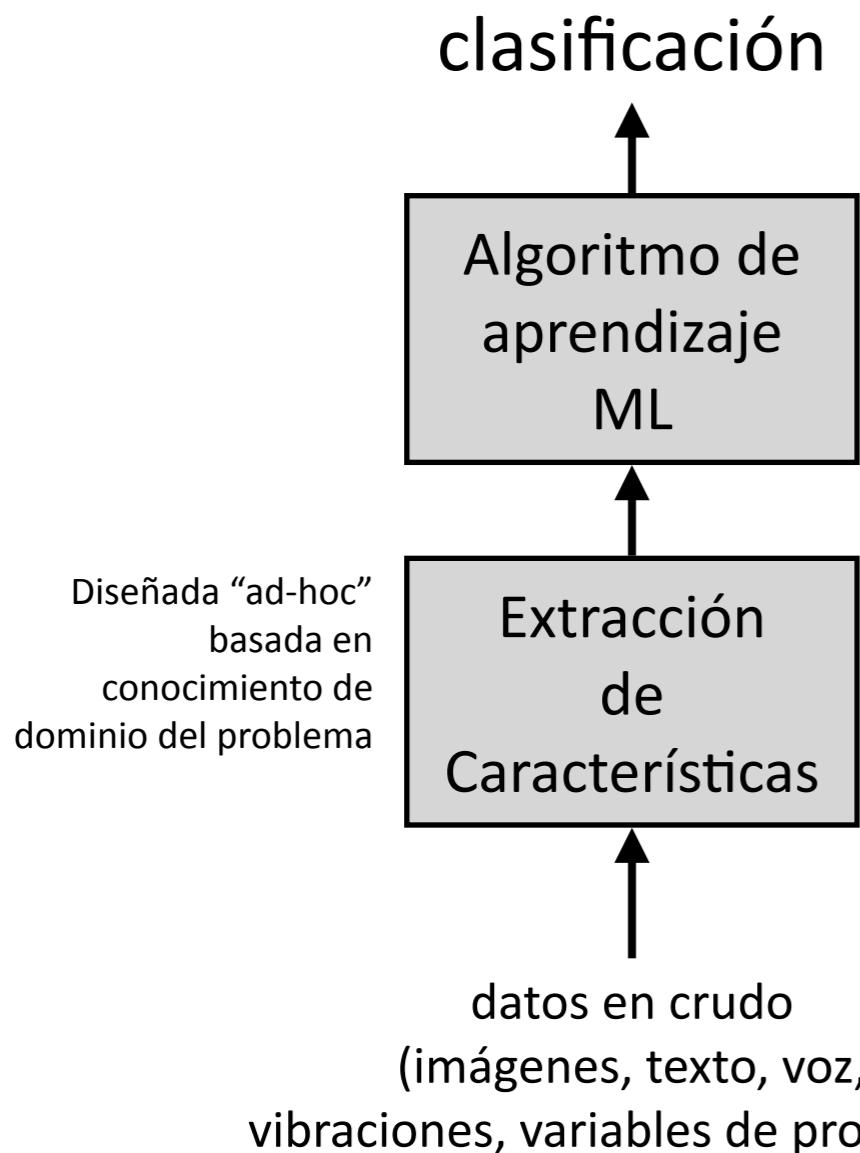
Los primeros niveles detectan características básicas (bordes, texturas)

Esas características se **componen** en los niveles superiores, creando detectores más complejos

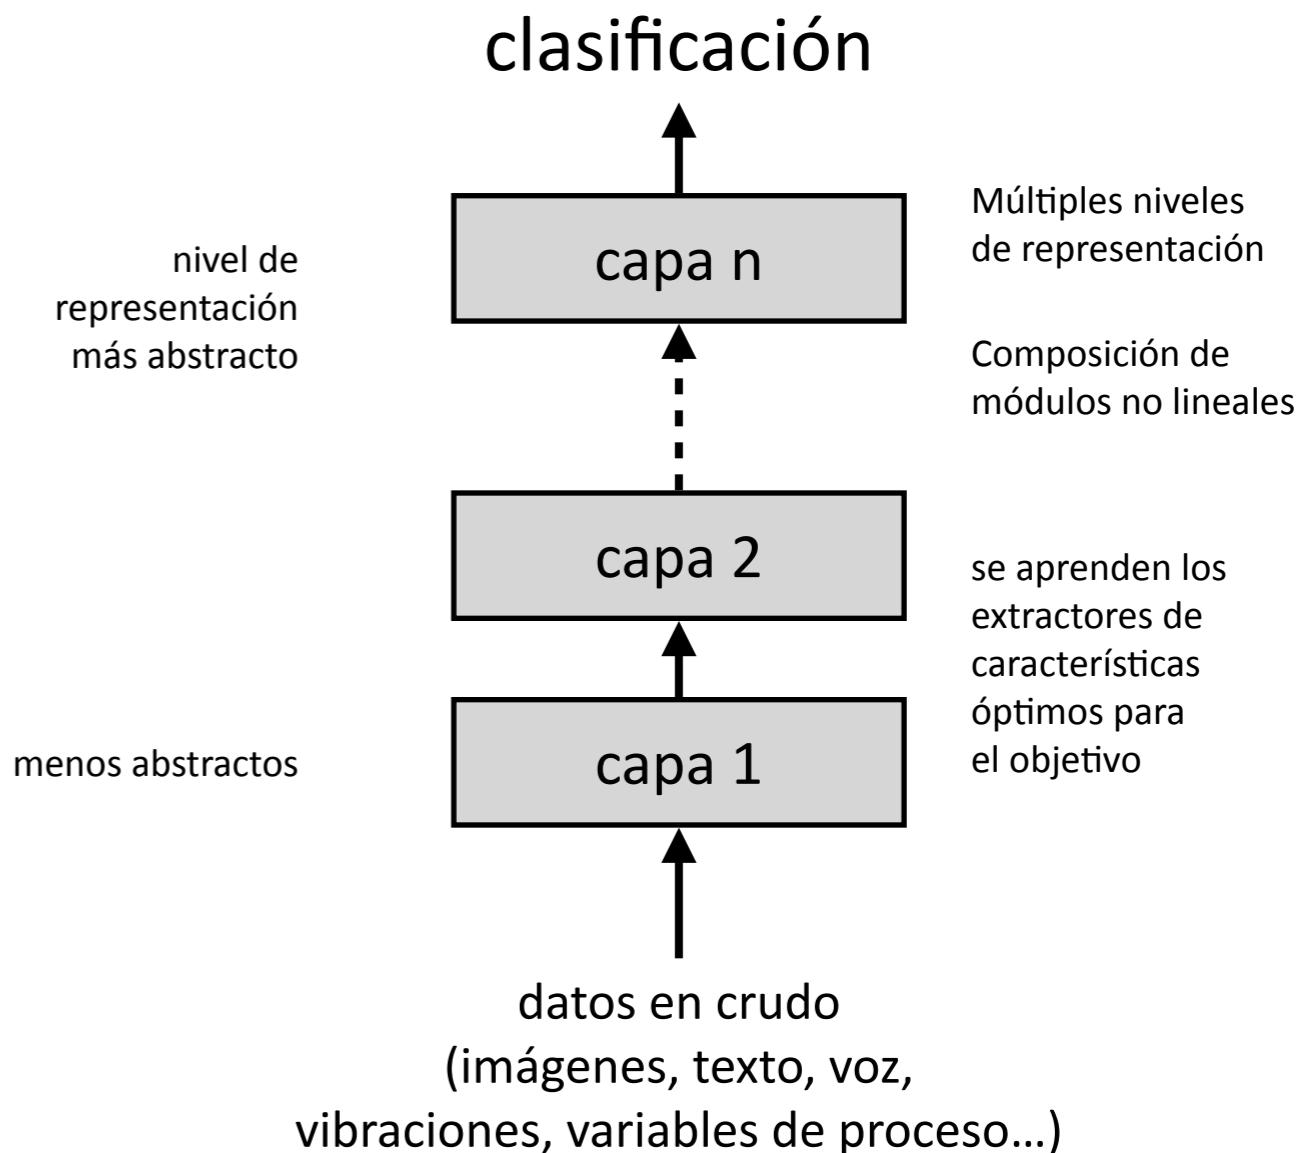
# ¿qué caracteriza al deep learning (DL)?

## “Representation Learning”

### Machine Learning convencional



### Deep Learning



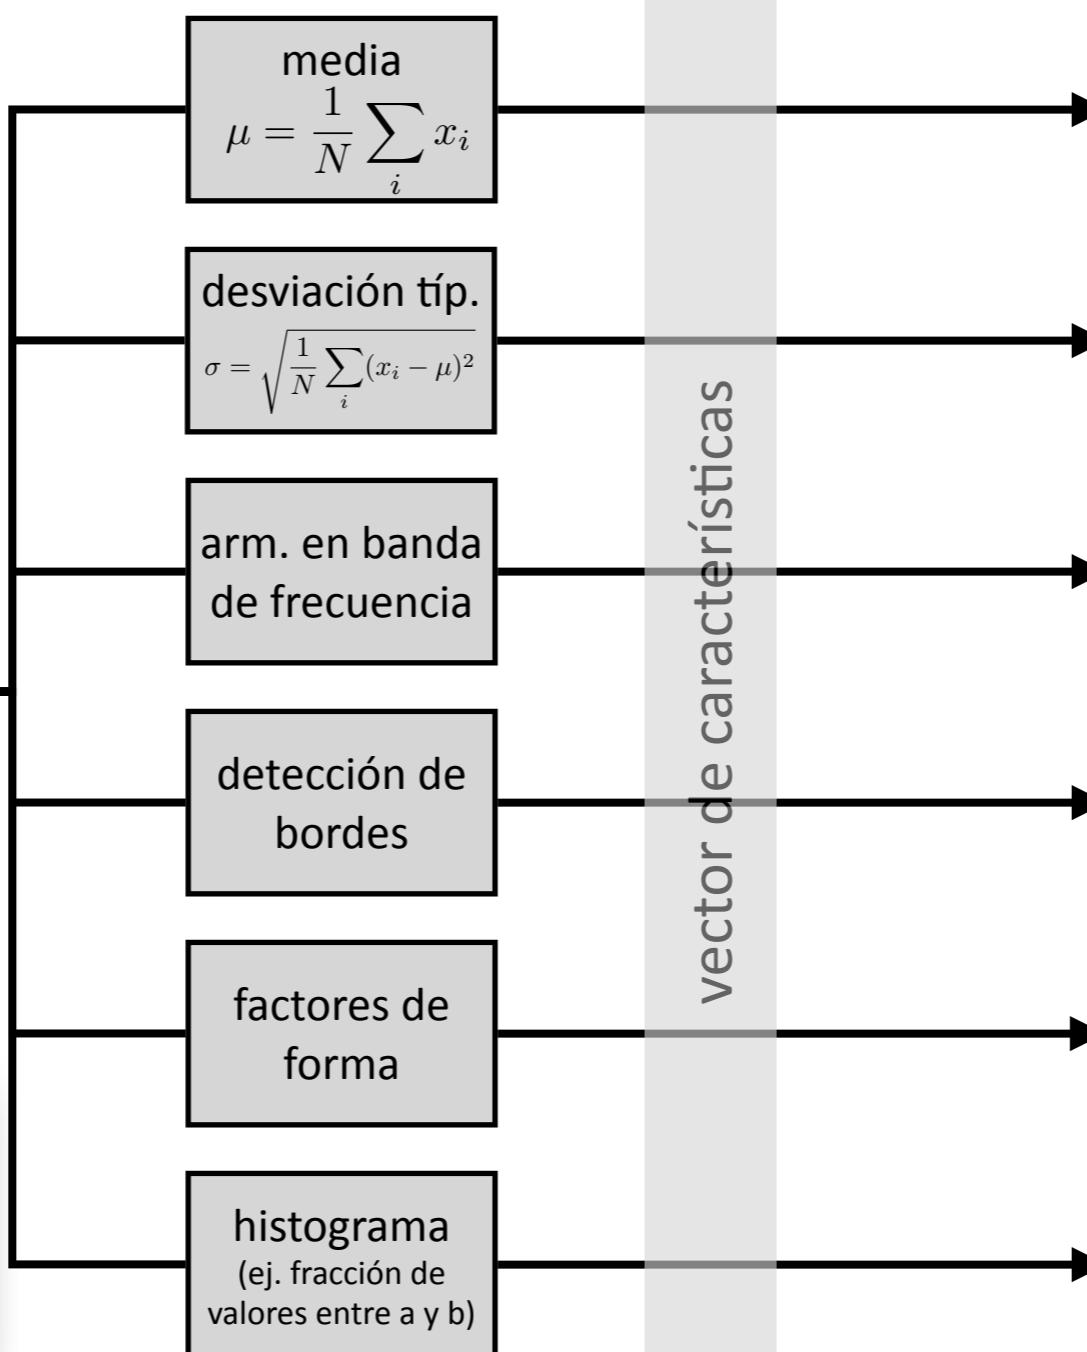
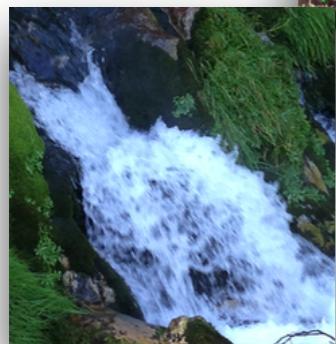
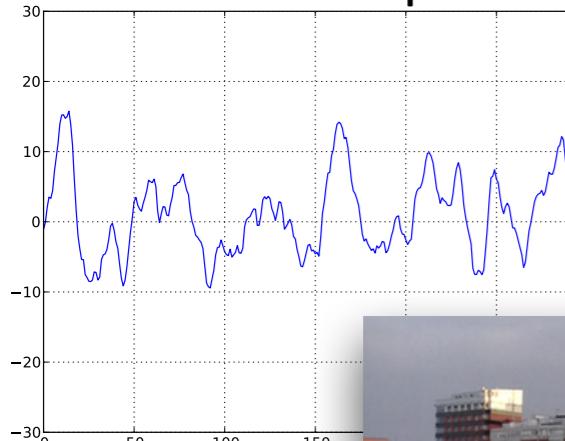
# ¿qué caracteriza al deep learning (DL)?

“Representation Learning”



(imágenes,  
texto, voz, vibraciones,  
variables de proceso...)

datos  
“en crudo” del proceso



descriptores basados en  
conocimiento de dominio  
del problema 40

Aprendizaje Máquina (ML)  
(clasificación, regresión, etc.)

Error  
Predicción

# ¿qué caracteriza al deep learning (DL)?

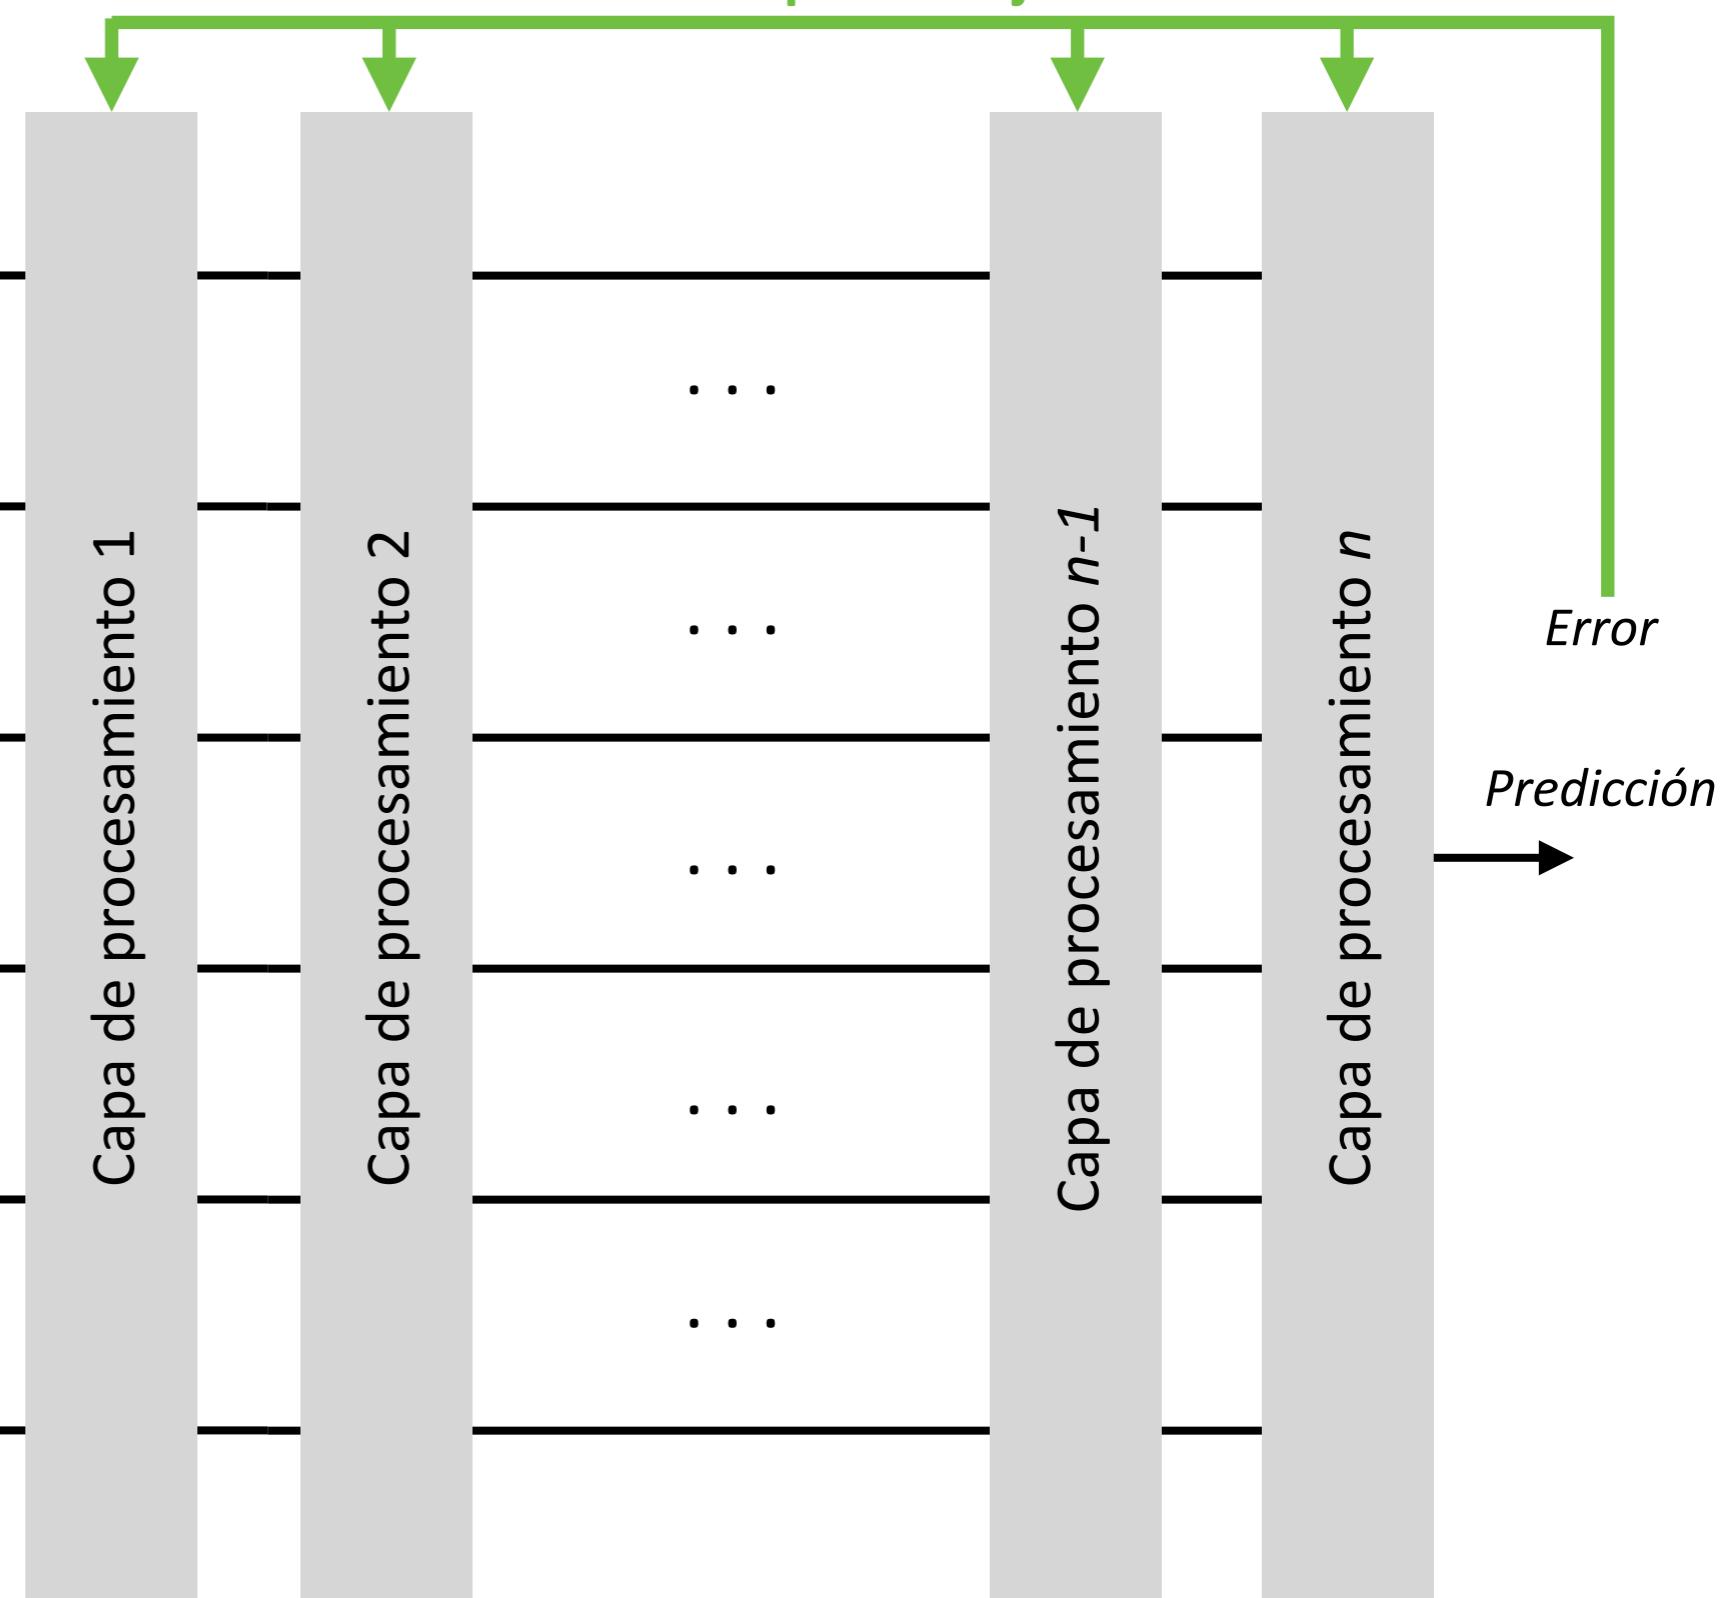
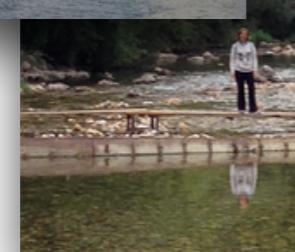
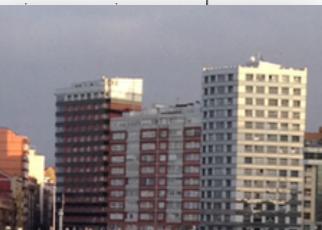
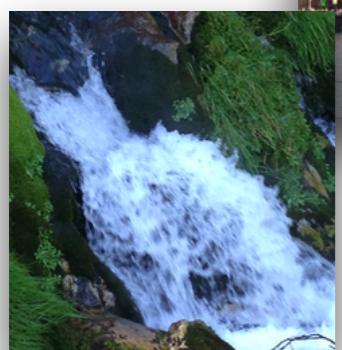
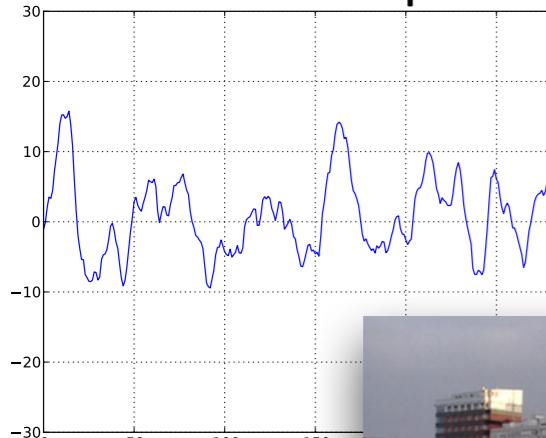
“Representation Learning”

aprendizaje



(imágenes,  
texto, voz, vibraciones,  
variables de proceso...)

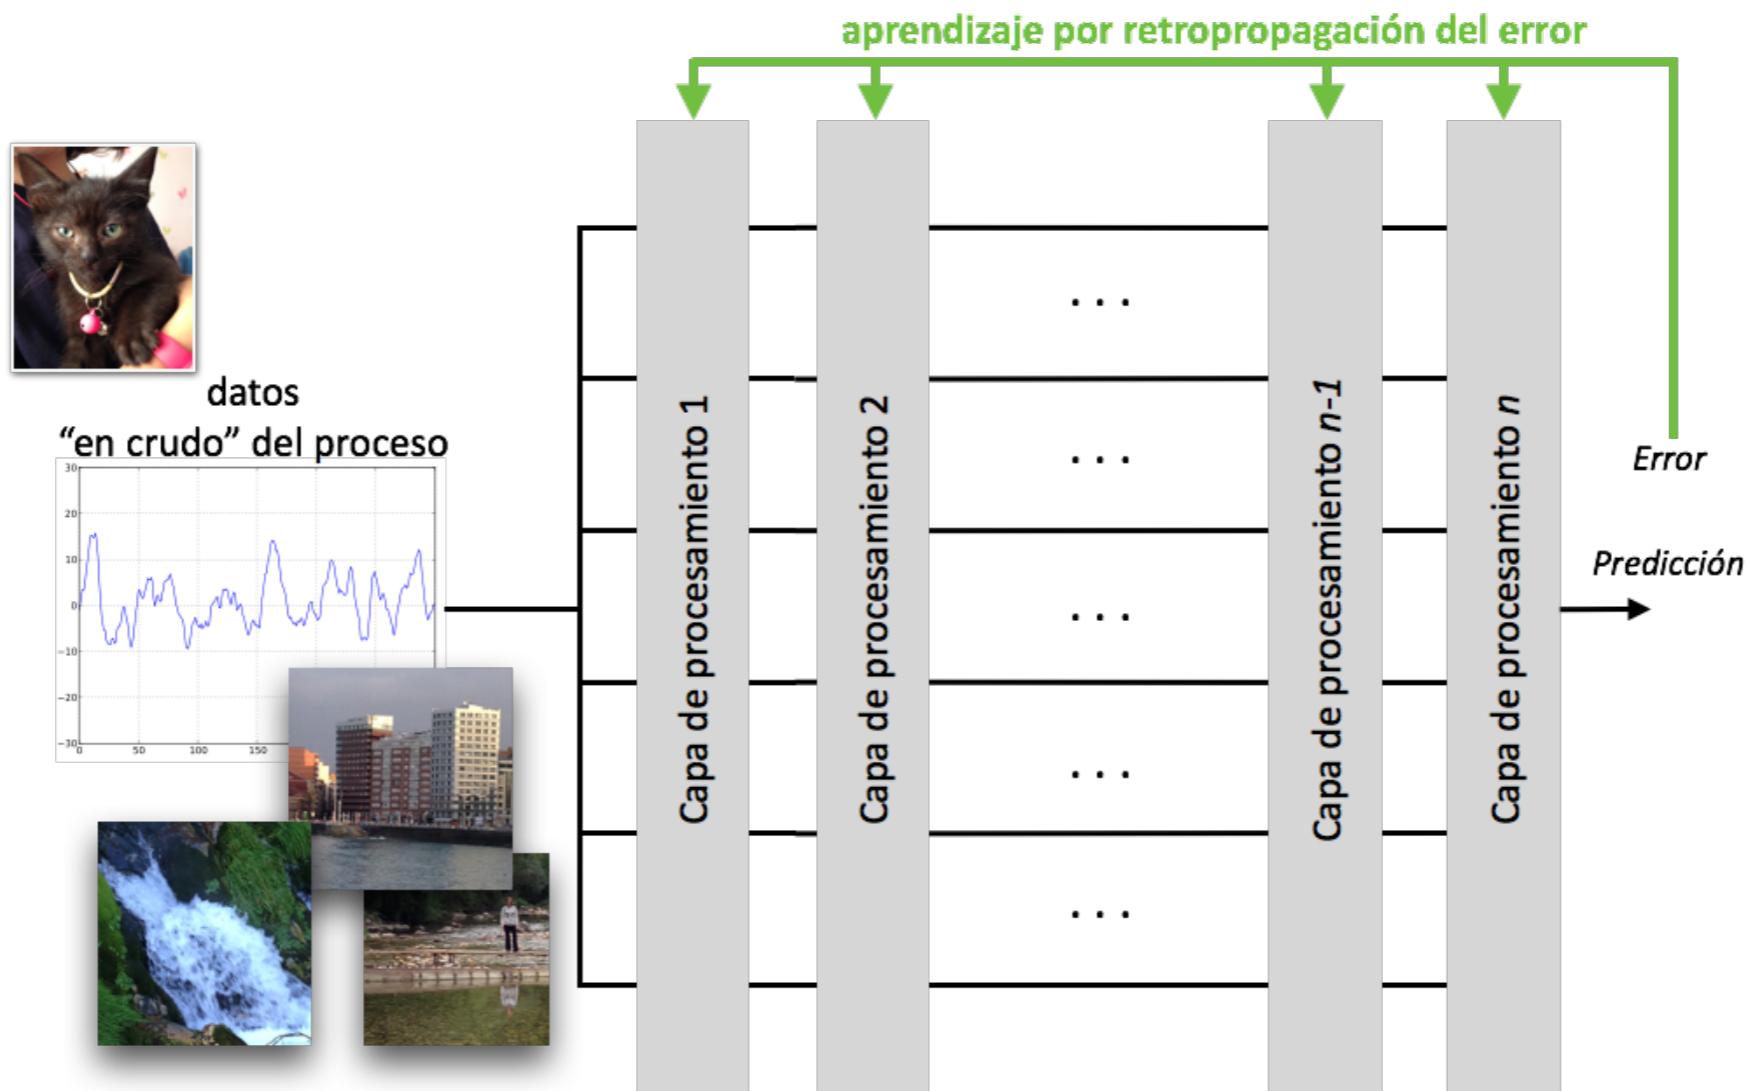
datos  
“en crudo” del proceso



¡descriptores aprendidos de ejemplos!

# ¿qué caracteriza al deep learning (DL)?

## “Representation Learning”



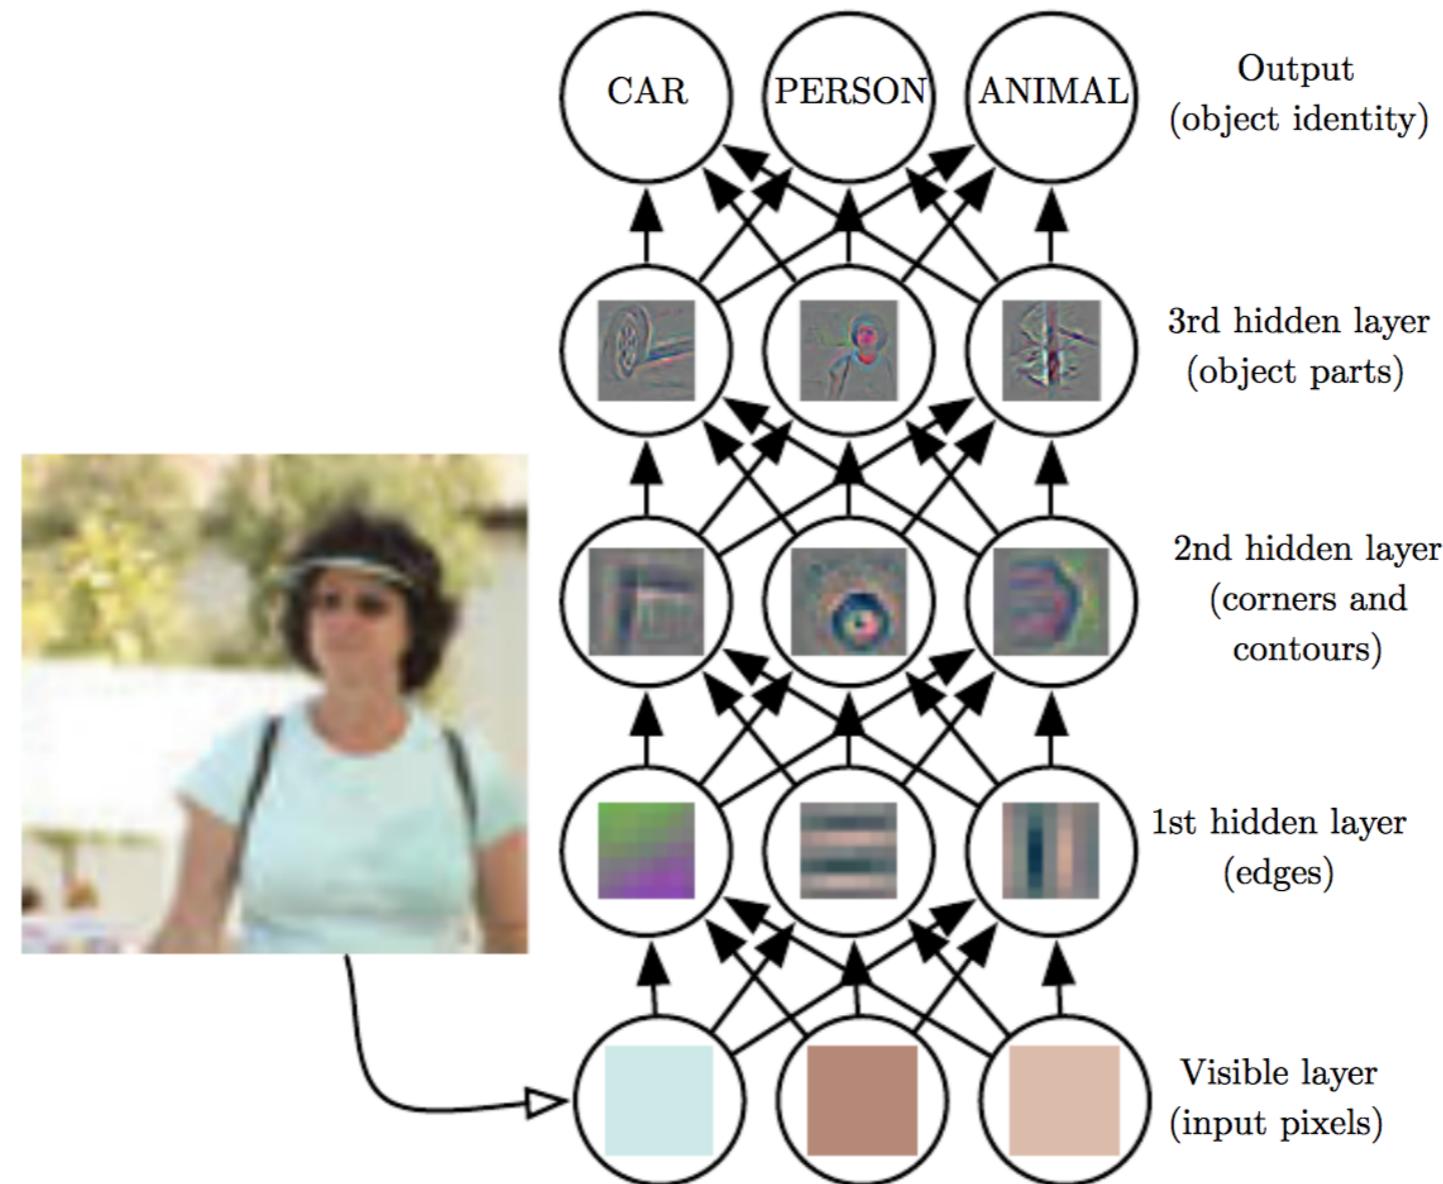
muchas señales naturales  
son composiciones de partes más simples  
agrupadas de forma jerárquica

**jerarquía  
composicional**

bordes → formas → partes → objetos

# ¿qué caracteriza al deep learning (DL)?

## “Representation Learning”



Fuente: I. Goodfellow, Y. Bengio, and A. Courville. Deep learning. MIT Press, 2016.

# ¿qué caracteriza al deep learning (DL)?

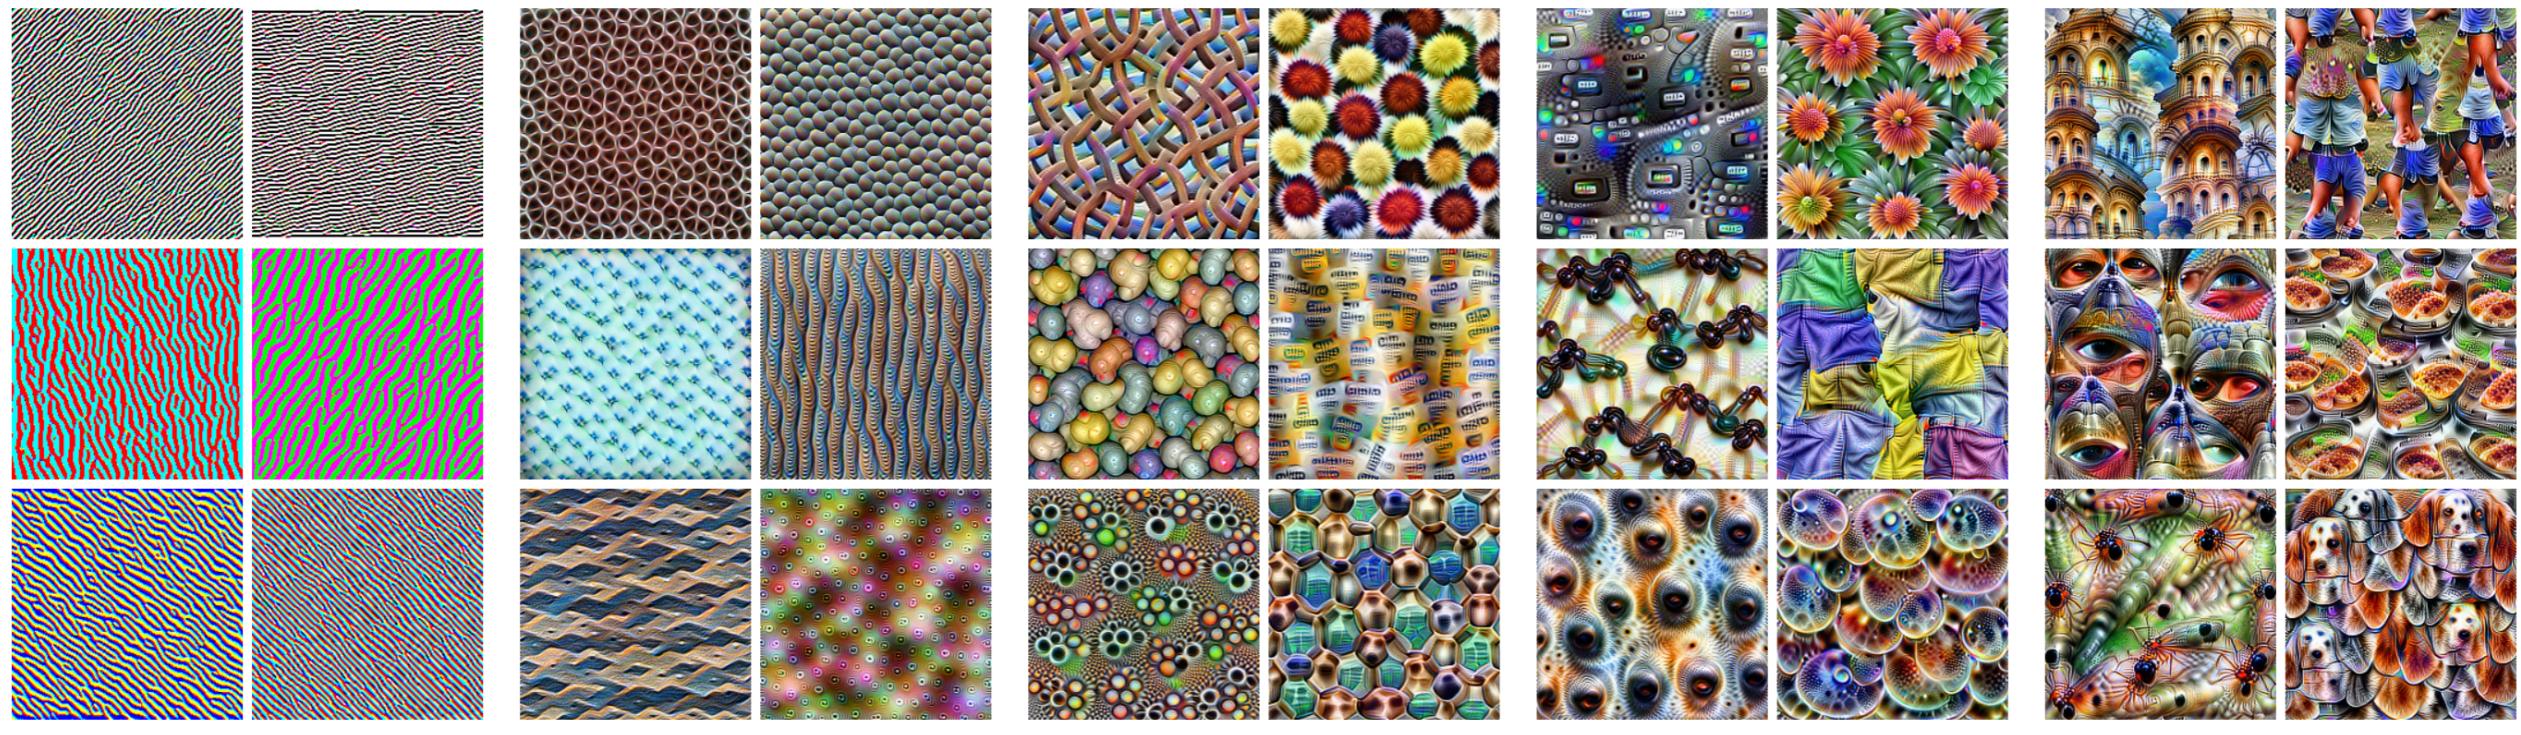
## “Representation Learning”

### Feature Visualization

Fuente: artículo fantástico en distill.pub  
sobre visualización de conocimiento adquirido por redes DL

Chris Olah, Alexander Mordvintsev, Ludwig Schubert → Google Brain / Google Research

<https://distill.pub/2017/feature-visualization/>



Edges (layer conv2d0)

Textures (layer mixed3a)

Patterns (layer mixed4a)

Parts (layers mixed4b & mixed4c)

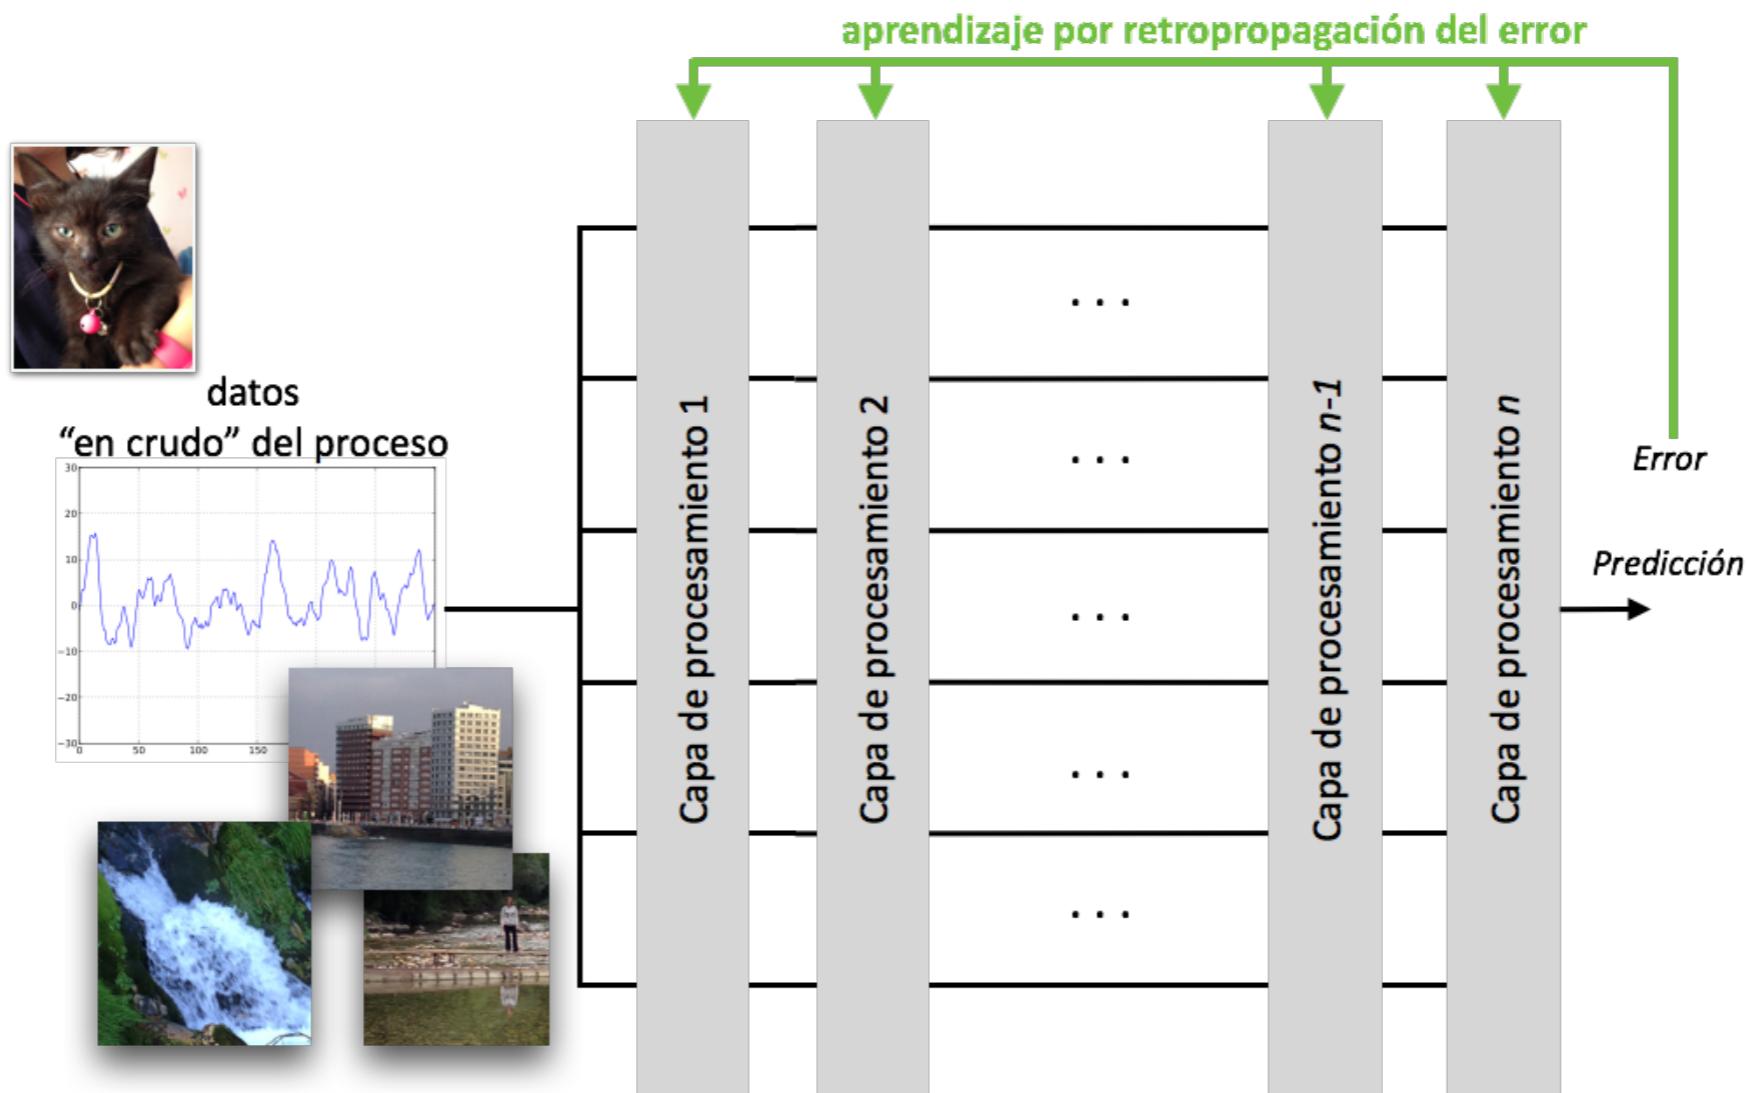
Objects (layers mixed4d & mixed4e)

Red “monstruosa”: GoogleLeNet  
Entrenada en ImageNet ( $\sim 10^6$  datos)  
Estimar ejemplos que causan cierto  
comportamiento (activación capa, salida...)

¡Emergen patrones  
de complejidad creciente  
hacia la salida!

# ¿qué caracteriza al deep learning (DL)?

## Complejidad



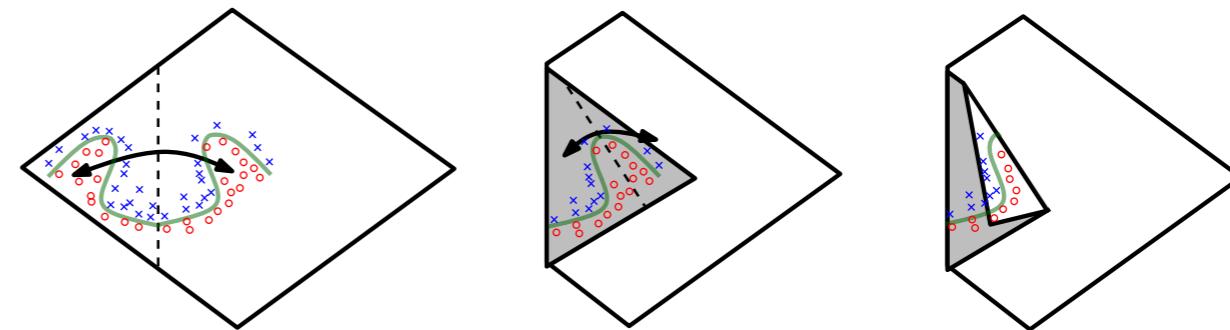
composición de transformaciones → funciones muy complejas

$$f(g(h(j(\dots(x))))) \rightarrow (f \circ g \circ h \circ j \dots)(x)$$

# ¿qué caracteriza al deep learning (DL)?

## Complejidad

Ventaja exponencial



fuente: Montufar et al 2014, "On the Number of Linear Regions of Deep Neural Networks"

Se reutilizan trozos de funciones de forma “composicional”

Una red poco profunda  
requiere exponencialmente más pesos  
que una profunda para aproximar ciertas funciones

Deep Learning es excelente en aprendizaje **no supervisado**, capaz de aprender cosas de ejemplos **sin etiquetar**

capacidad de “desenredar” datos (“disentangling”)

Descubre estructuras complejas en conjuntos de datos enormes

transfer learning

A partir de ahí, puede resolver problemas **supervisados** en los que hay “pocas” etiquetas

¡ Hasta aquí no parece haber  
muchas diferencias con las RN convencionales !

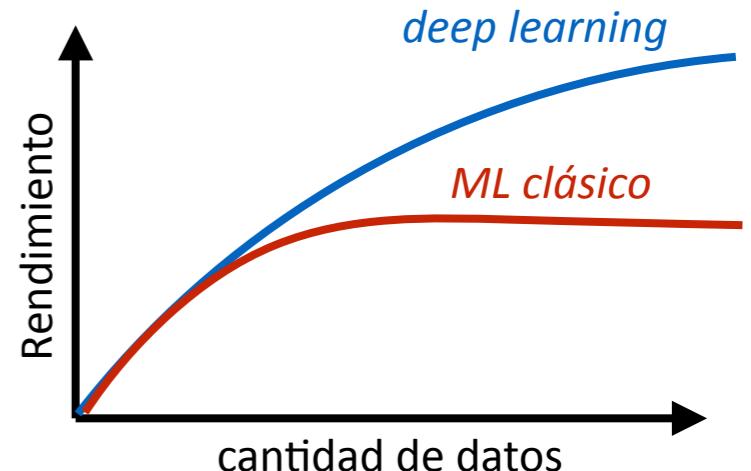
- mismo entrenamiento → backpropagation
- misma arquitectura

¿lo mismo que antes, pero con más capas?



- **profundidad**  
 backpropagation “a secas”  
 no entrena bien capas profundas  
 (vanishing gradient)
- **generalización**  
 muchas dimensiones y pocos ejemplos
  - imágenes ( $10^4 \sim 10^6$  dim)
  - texto ( $\sim 10^5$  dim)
 → generalización
- **complejidad**  
 optimizar funciones con millones de pesos

- **Escalabilidad**  
 cuantos más datos manejan,  
 mejor es su comportamiento

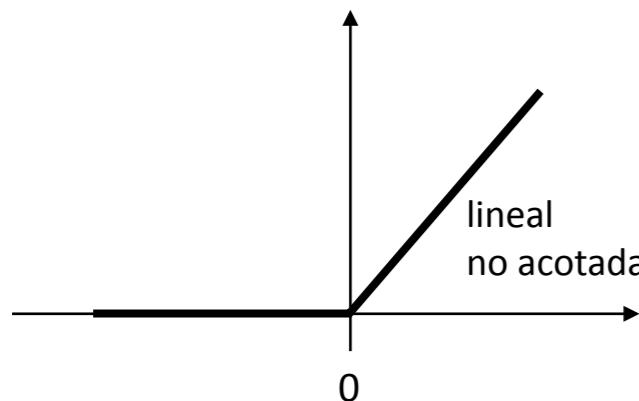


# Avances clave en DL

## Mejoras en los algoritmos

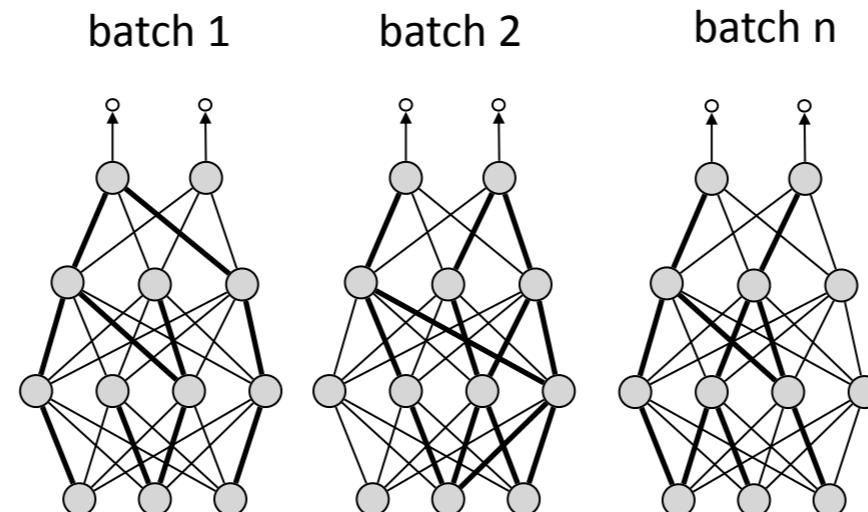
### Funciones de activación

#### ReLU



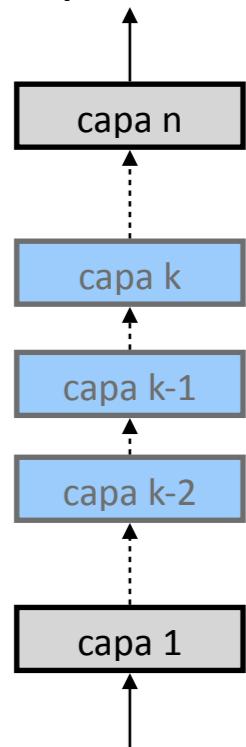
No acotada como la sigmoide  
Permite gradientes altos en capas ocultas  
Solventa el problema de “shallow gradient”

### Regularización (dropout)

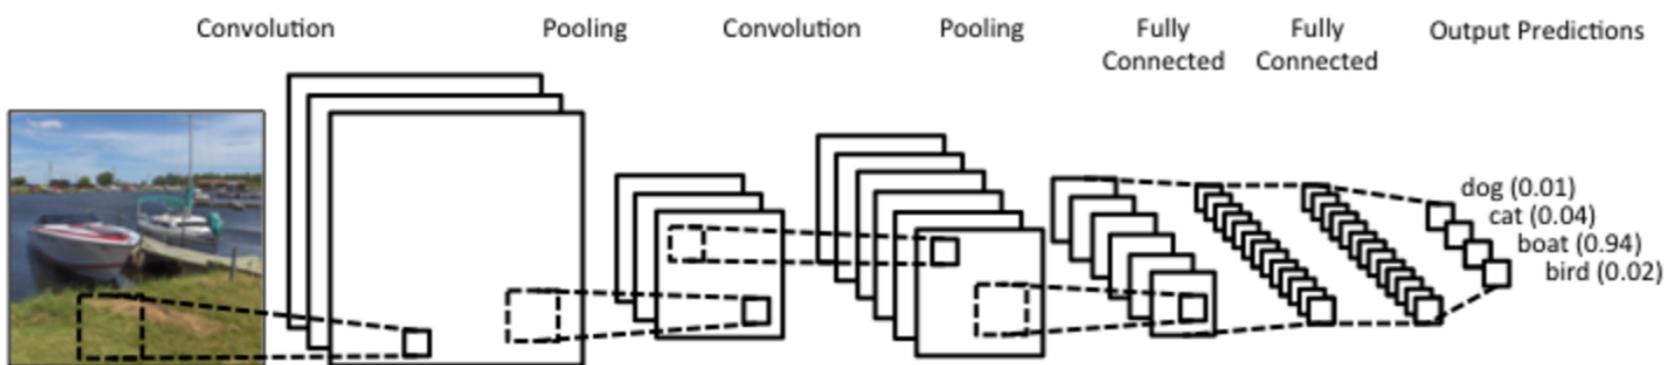


Bloqueo del entrenamiento de algunos pesos,  
equivale a un “ensemble” de muchas redes distintas  
Ejerce efecto de regularización → mejor generalización

### entrenamiento de capas profundas



### Redes convolucionales

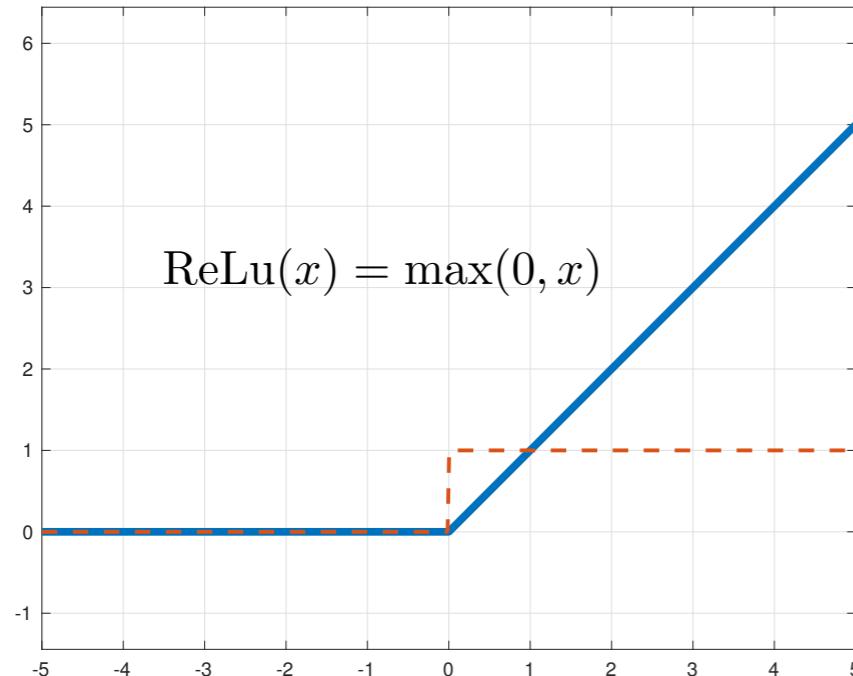


Fuente: <http://www.wildml.com/2015/11/understanding-convolutional-neural-networks-for-nlp/>

op. de convolución → **implementable en GPU**  
**coherencia** → estadísticos locales **invariantes a localización**  
 (un motivo puede aparecer igual en varios sitios)  
**Ejemplos sintéticos** (rotación, traslación, deformación)  
<http://isa.uniovi.es/GSDPI>

# Avances clave en DL

## Rectifier Linear Units (ReLU)

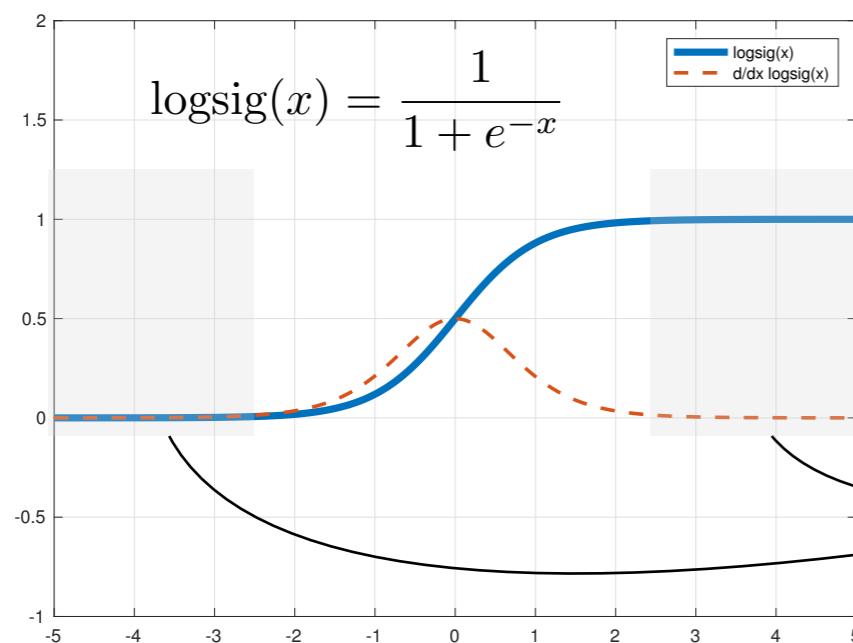


lineal, no acotada

Permite **gradientes altos**  
en capas ocultas

Solventa el problema  
“shallow gradient”

su carácter “hard” favorece  
la dispersión (*sparsity*)



acotada

derivadas casi nulas  
en los extremos

→ **gradientes casi nulos**  
**los pesos no avanzan**  
(la red no aprende)

sustituyendo las sigmoidales por ReLu  

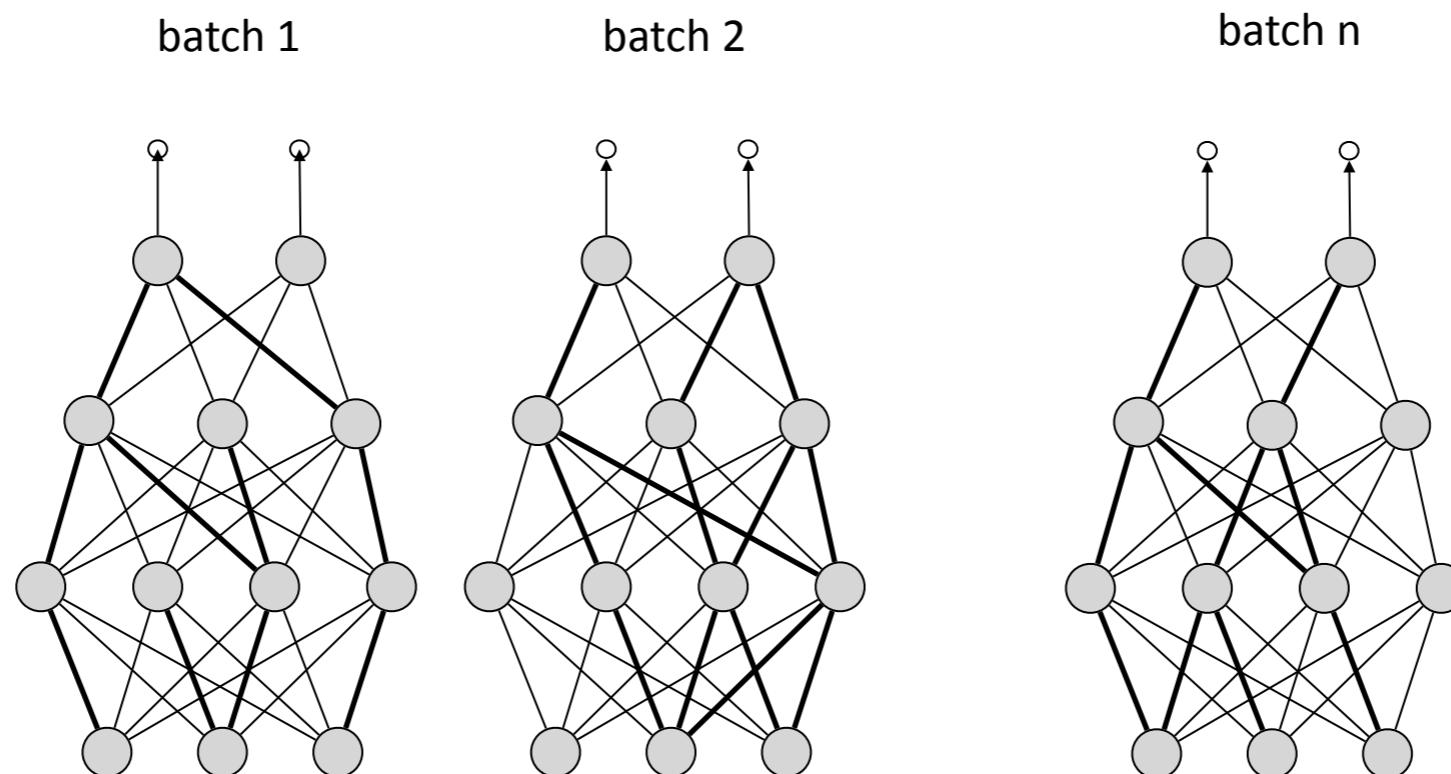
- se mejora la generalización
- el aprendizaje DL es más rápido y simple

M. D. Zeiler, M. Ranzato, R. Monga, M. Mao, K. Yang, Q. V. Le, P. Nguyen, A. Senior, V. Vanhoucke, J. Dean, et al. On rectified linear units for speech processing. In *Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on*, pages 3517–3521. IEEE, 2013.

# Avances clave en DL

## Dropout

Bloqueo del entrenamiento de algunos pesos,  
equivale a un “ensemble” de muchas redes distintas  
Ejerce efecto de regularización → mejor generalización



# Avances clave en DL

## Redes convolucionales

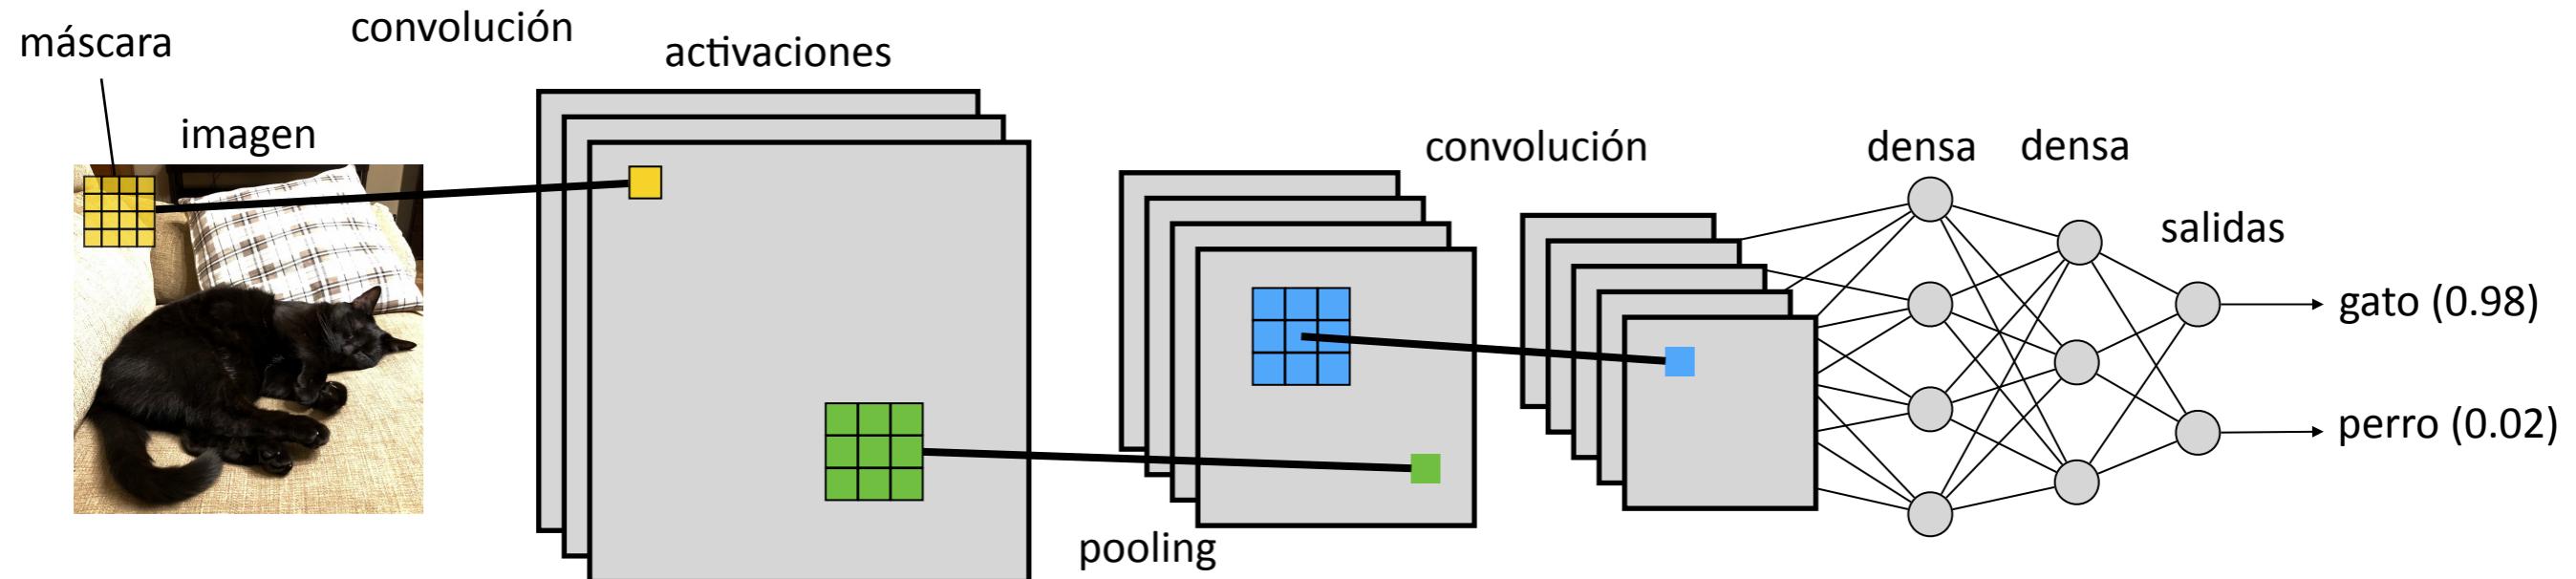
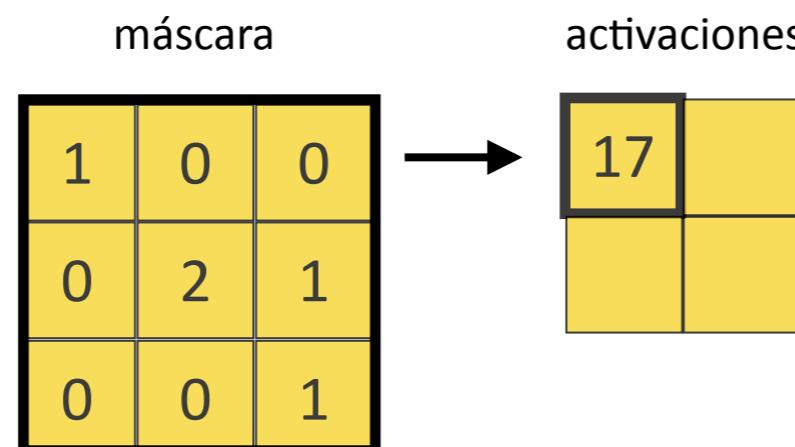


imagen			
5	0	1	0
3	5	1	2
3	2	1	0
4	1	3	1



$$5 \times 1 + 0 \times 0 + 1 \times 0 + \\ 3 \times 0 + 5 \times 2 + 1 \times 1 + \\ 3 \times 0 + 2 \times 0 + 1 \times 1 = 17$$

los pesos de la máscara  
son **adaptados** para  
alcanzar un objetivo  
definido por una  
**función de coste**

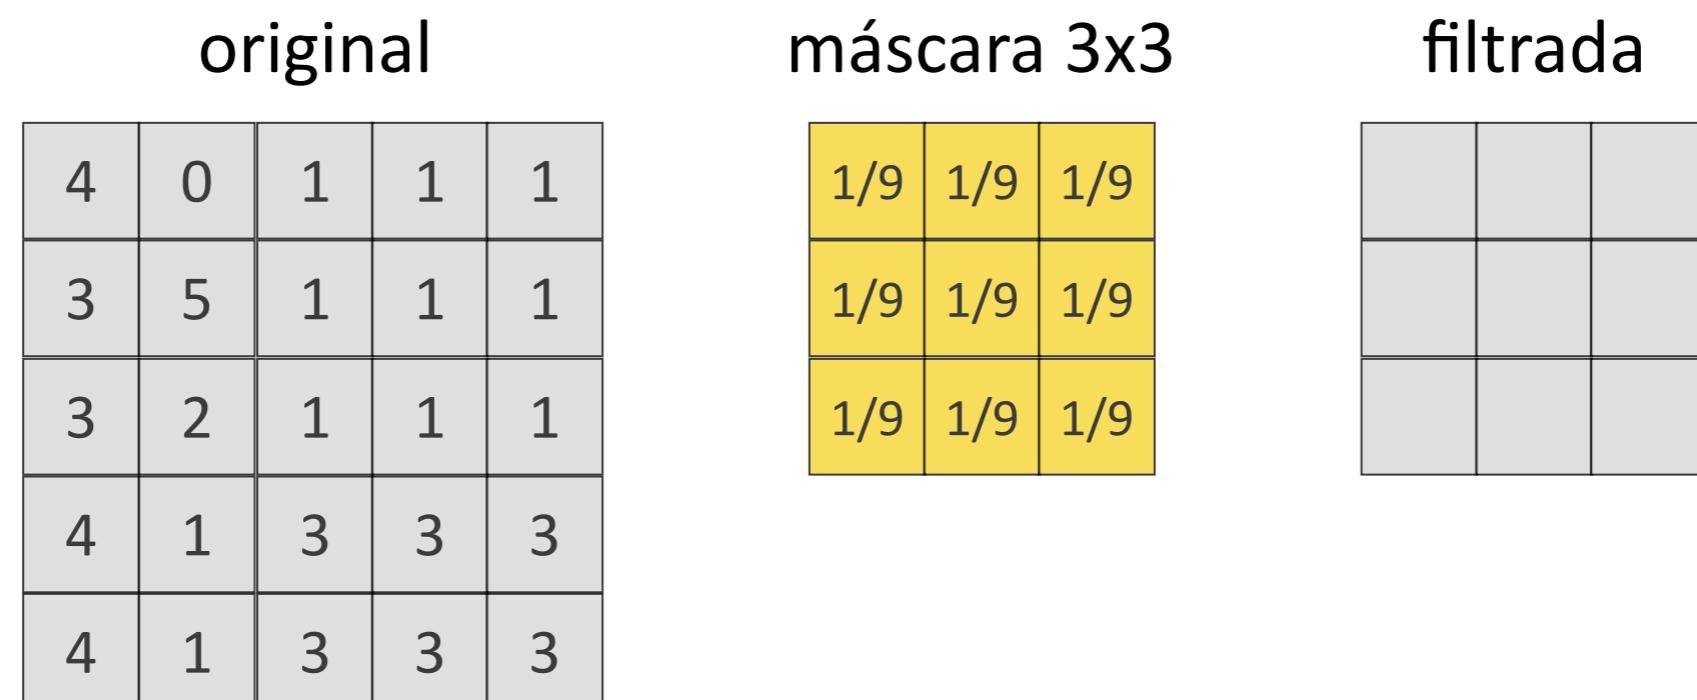
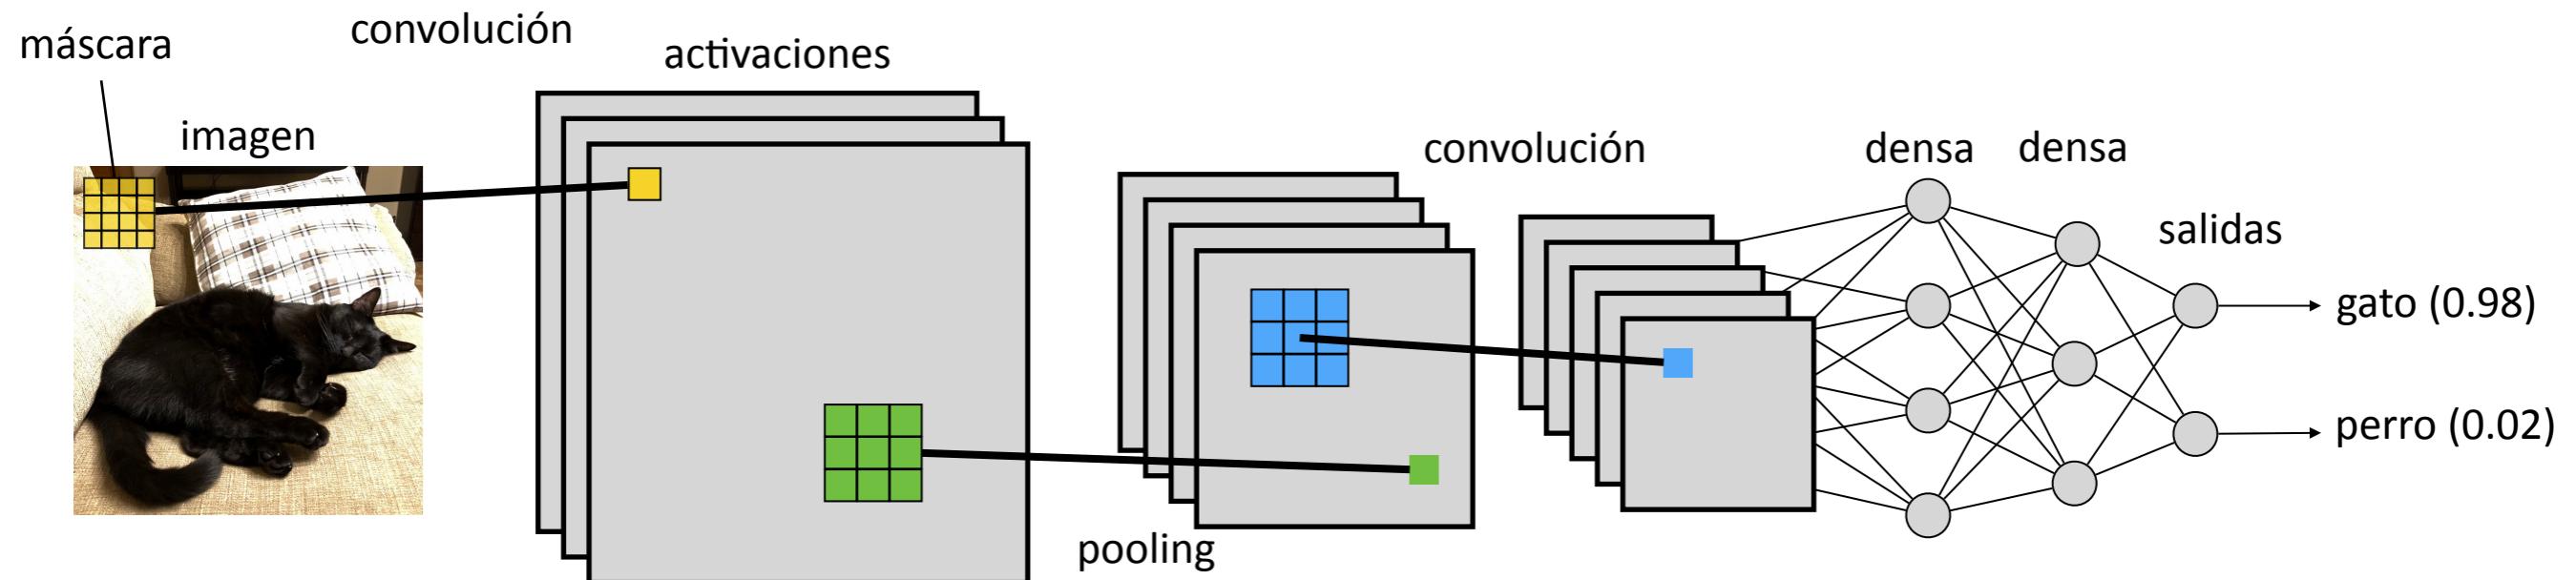
una capa convolución  
usa **muchos menos pesos**  
que una densa  
(todos con todos)

Explota principios  
de **coherencia** (estadísticos locales  
se preservan)  
y **jerarquía composicional**  
los elementos se unen  
como <sup>53</sup> piezas de un lego

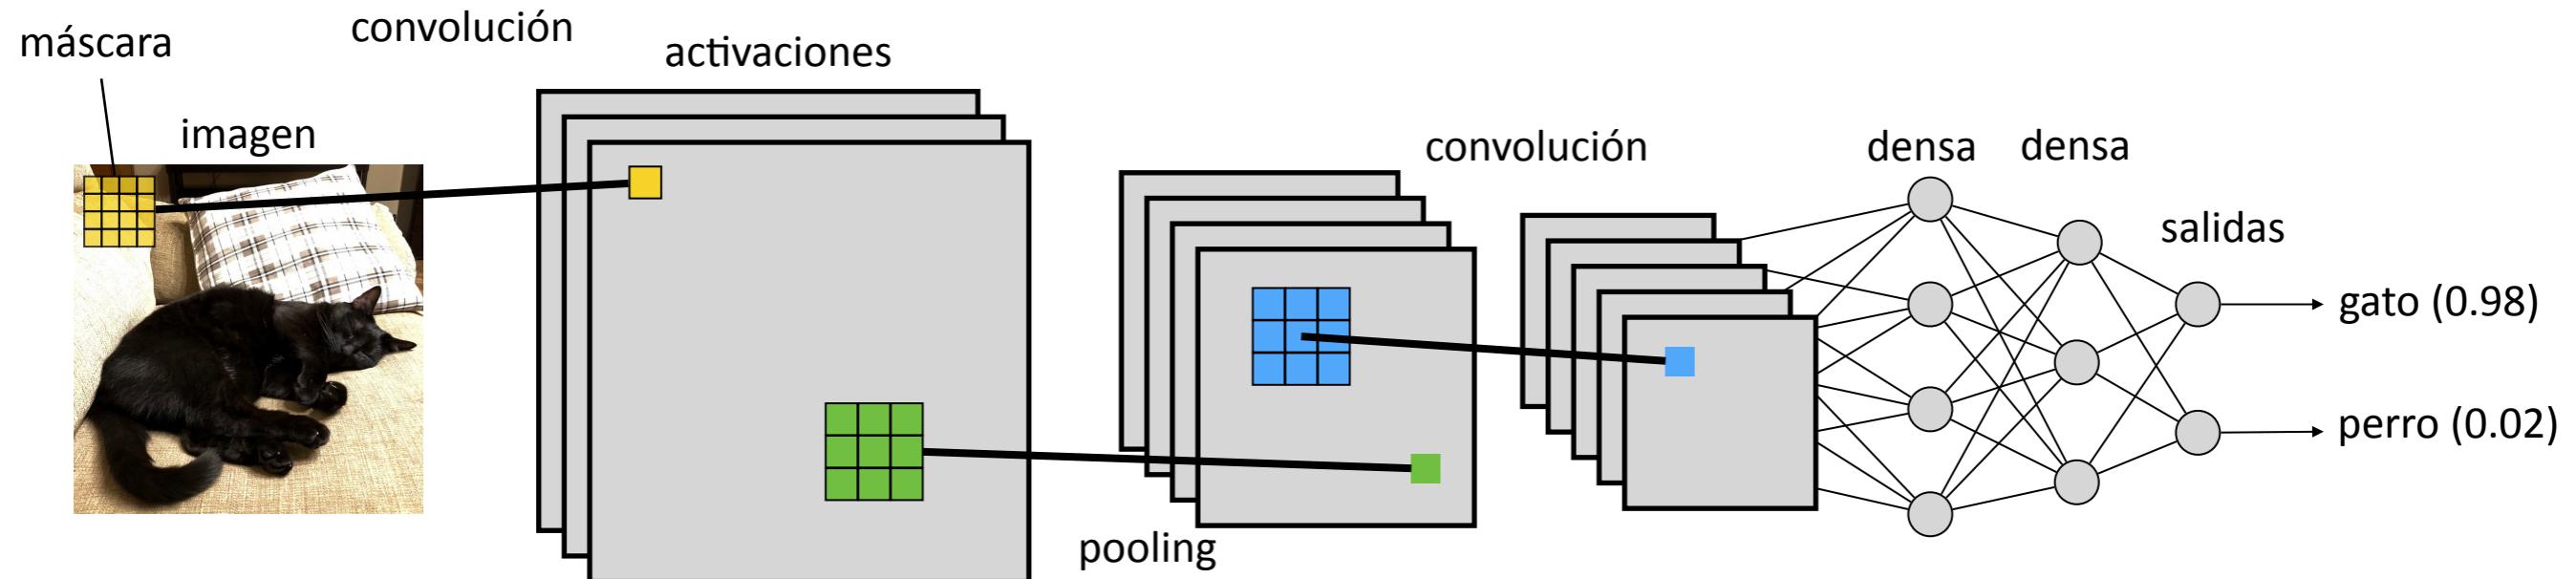
Suelen utilizarse  
**ejemplos sintéticos**  
(rotación, traslación,  
deformación)

# Avances clave en DL

## Redes convolucionales



## Operación de convolución



**original**

4	0	1	1	1
3	5	1	1	1
3	2	1	1	1
4	1	3	3	3
4	1	3	3	3

**máscara 3x3**

1/9	1/9	1/9
1/9	1/9	1/9
1/9	1/9	1/9

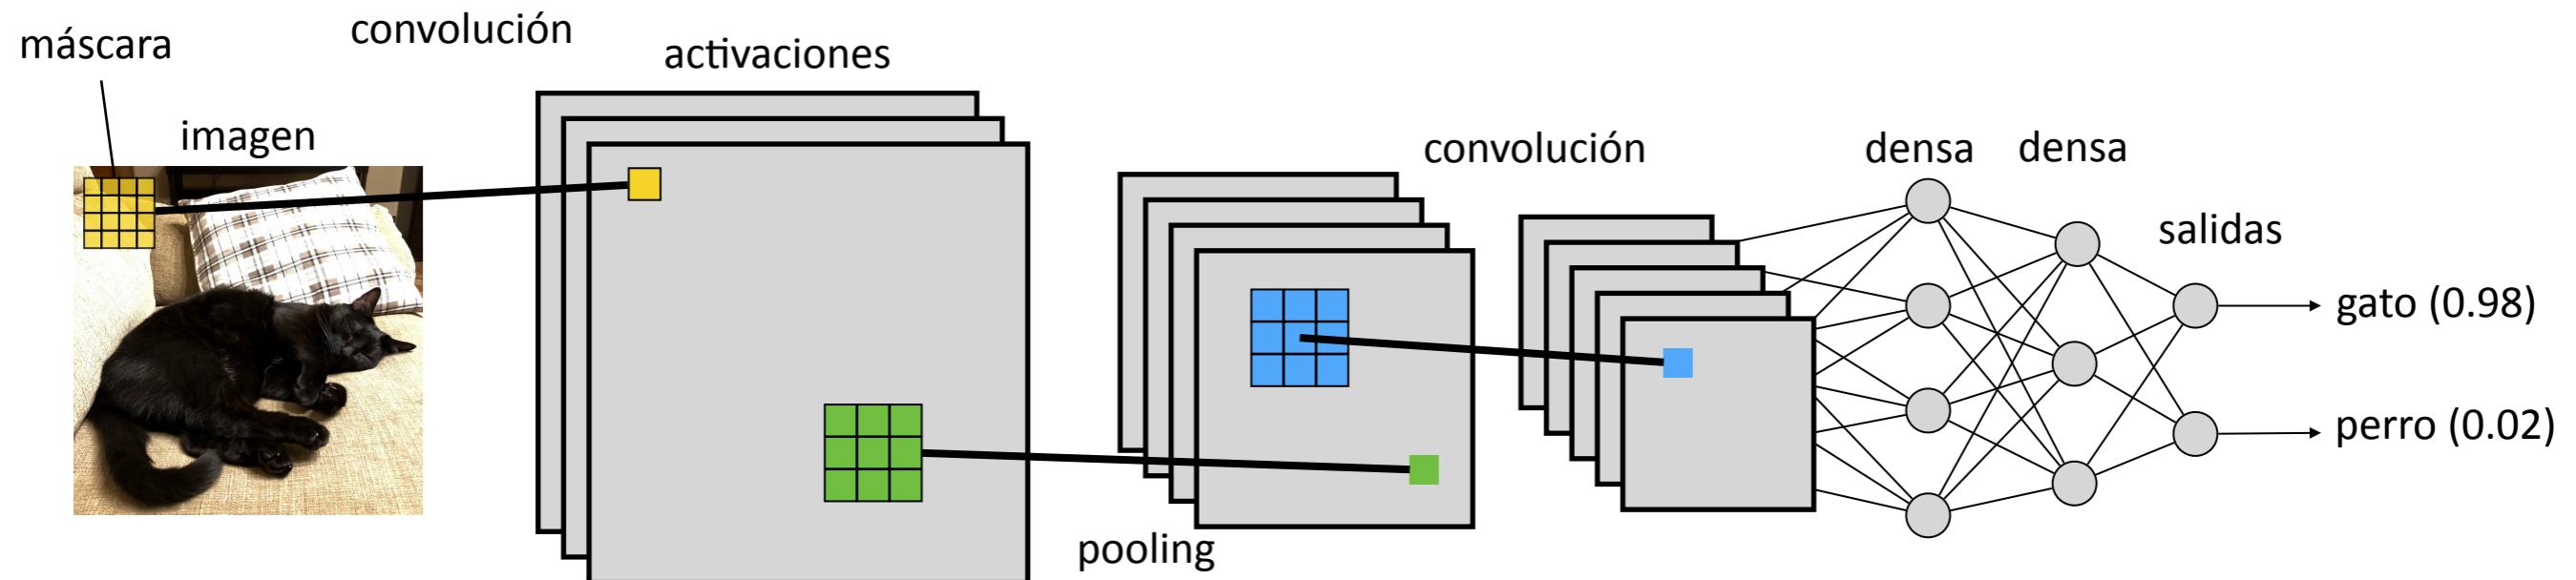
**filtrada**

2,2		

## Operación de convolución

# Avances clave en DL

## Redes convolucionales

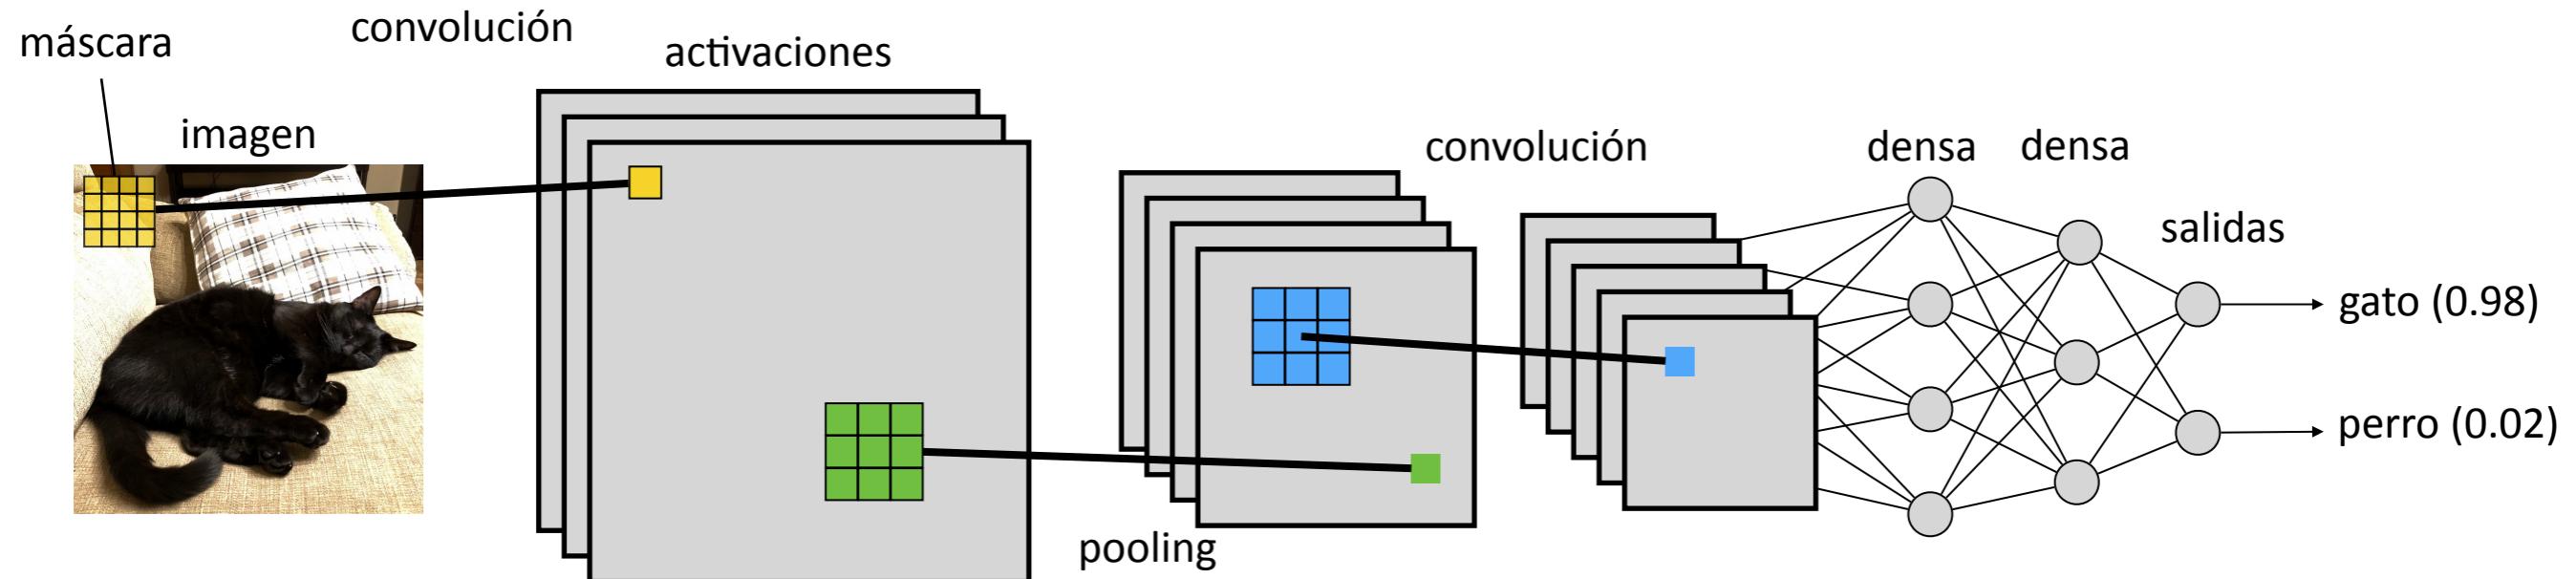


original				
5	0	1	1	1
3	5	1	1	1
3	2	1	1	1
4	1	3	3	3
4	1	3	3	3

máscara 3x3		
1/9	1/9	1/9
1/9	1/9	1/9
1/9	1/9	1/9

filtrada		
2,2	1,4	

## Operación de convolución



original

5	0	1	1	1
3	5	1	1	1
3	2	1	1	1
4	1	3	3	3
4	1	3	3	3

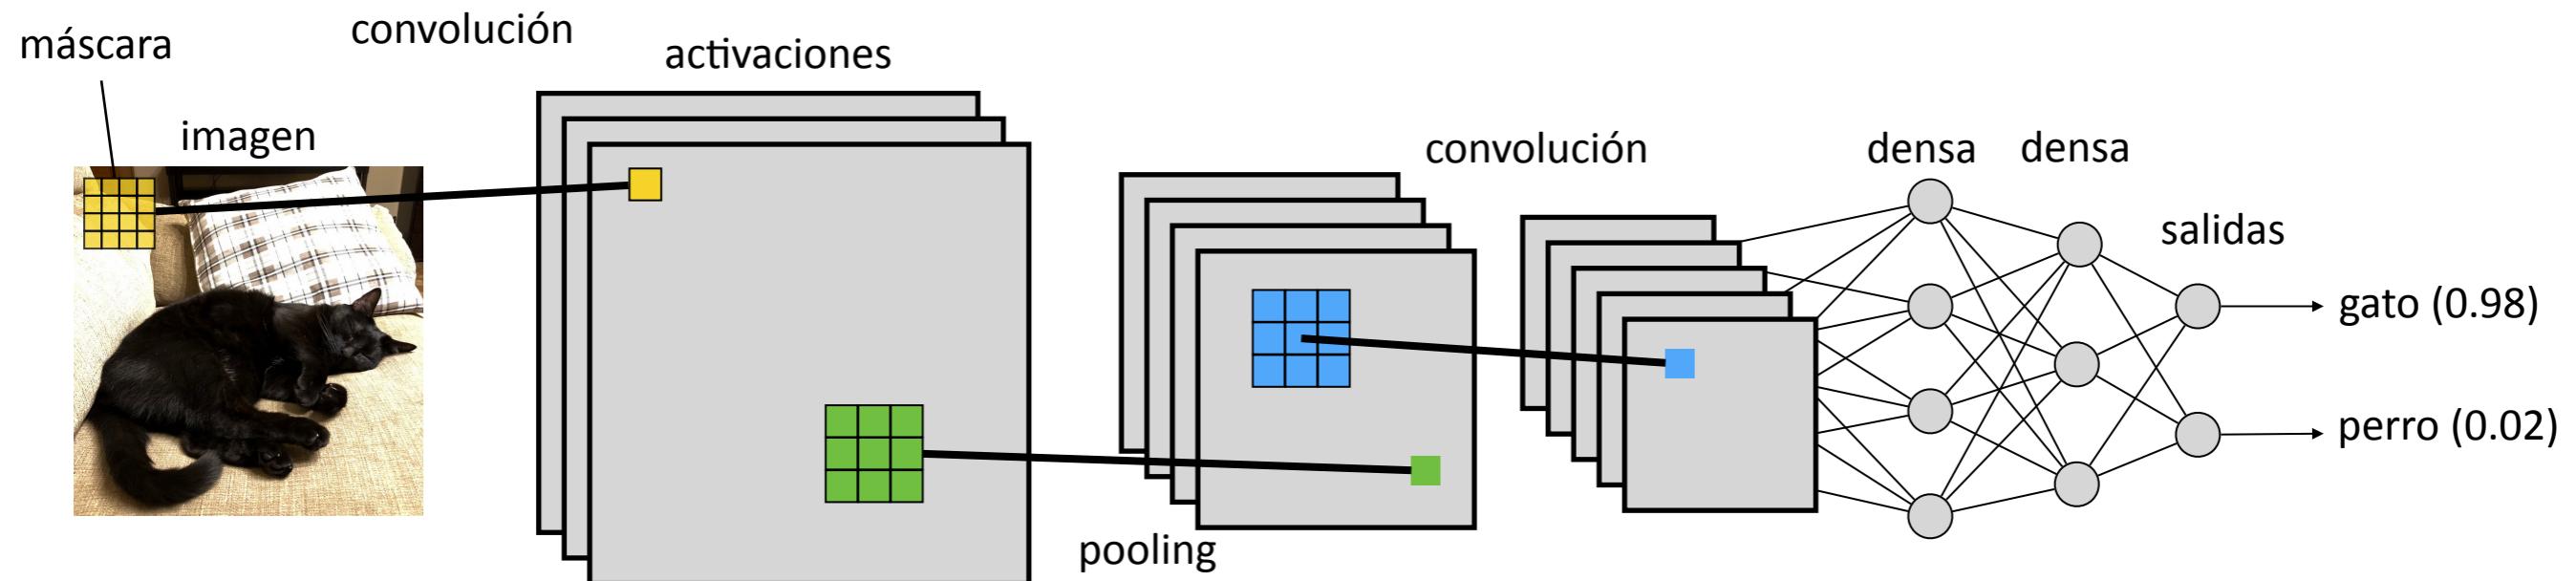
máscara 3x3

1/9	1/9	1/9
1/9	1/9	1/9
1/9	1/9	1/9

filtrada

2,2	1,4	1

## Operación de convolución



original

5	0	1	1	1
3	5	1	1	1
3	2	1	1	1
4	1	3	3	3
4	1	3	3	3

máscara 3x3

1/9	1/9	1/9
1/9	1/9	1/9
1/9	1/9	1/9

filtrada

2,2	1,4	1
2,5		

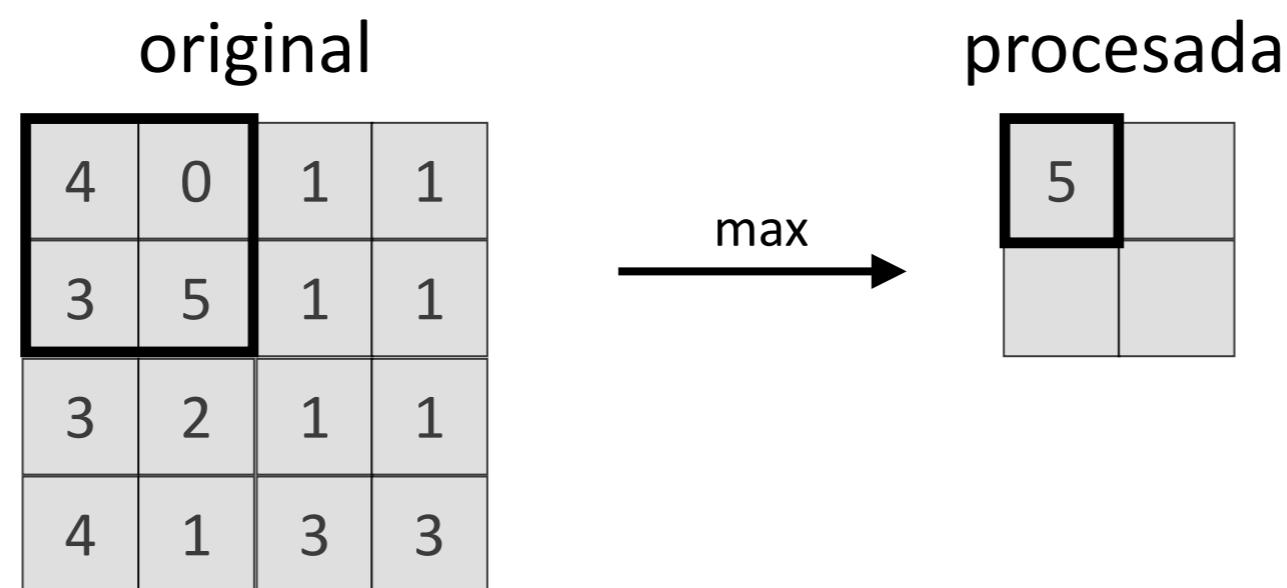
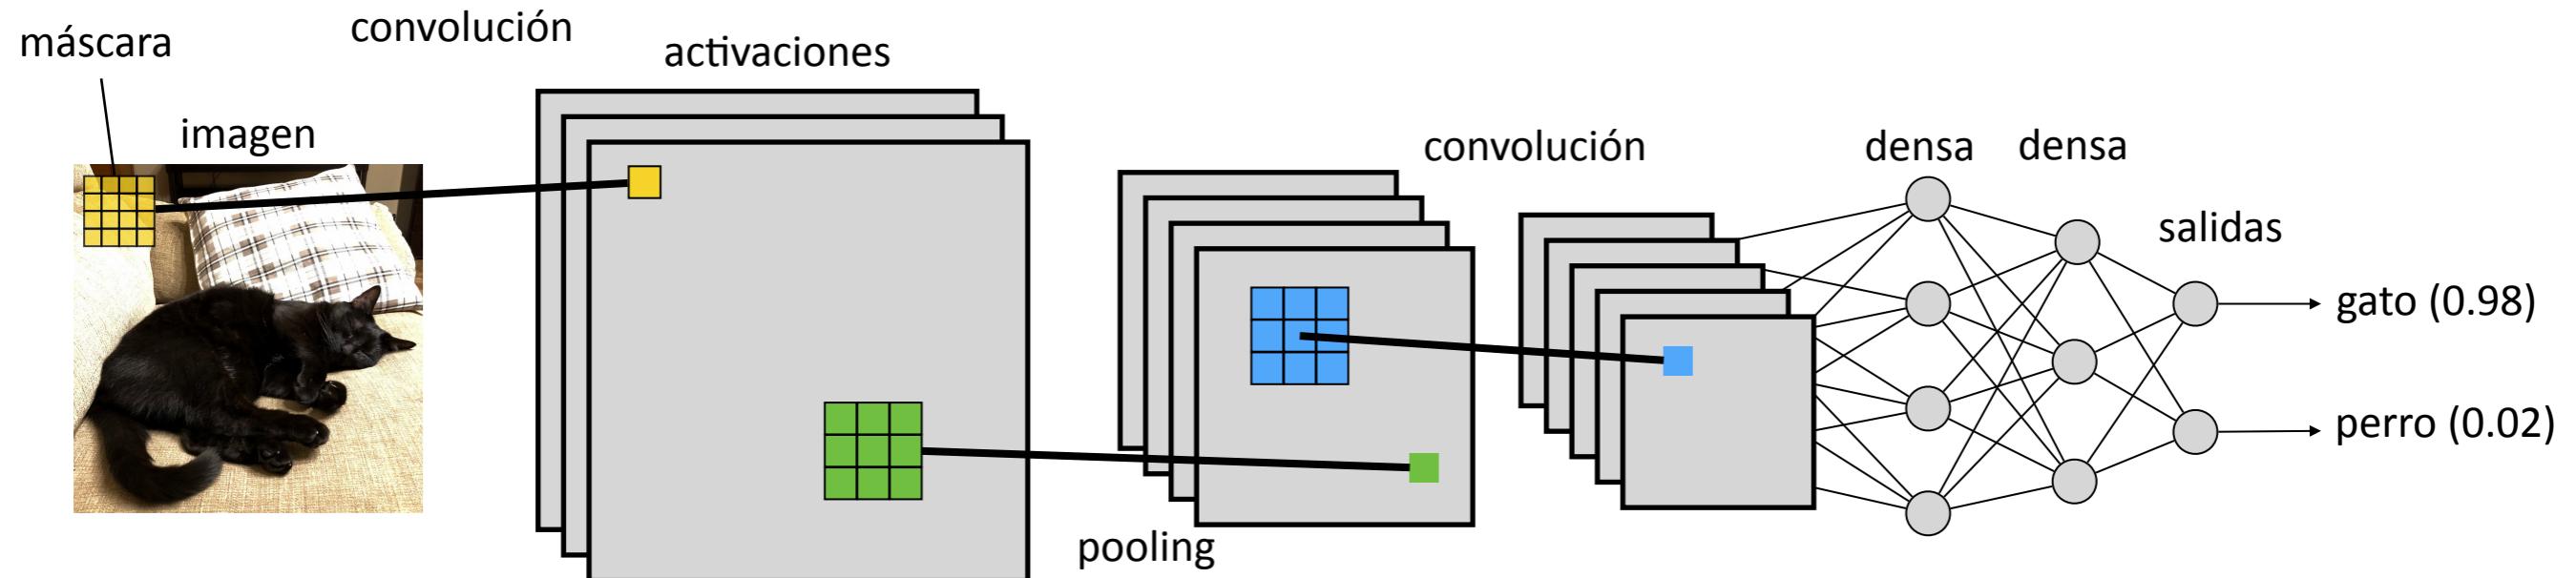
## Operación de convolución

La convolución es un filtro  
**sensible a patrones concretos**

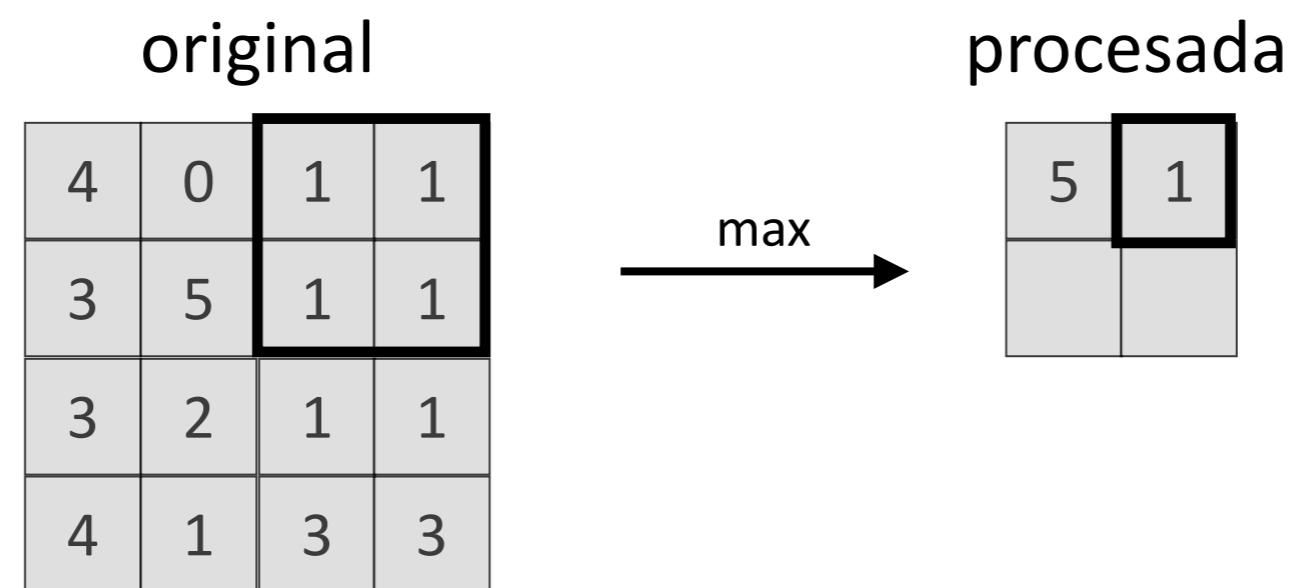
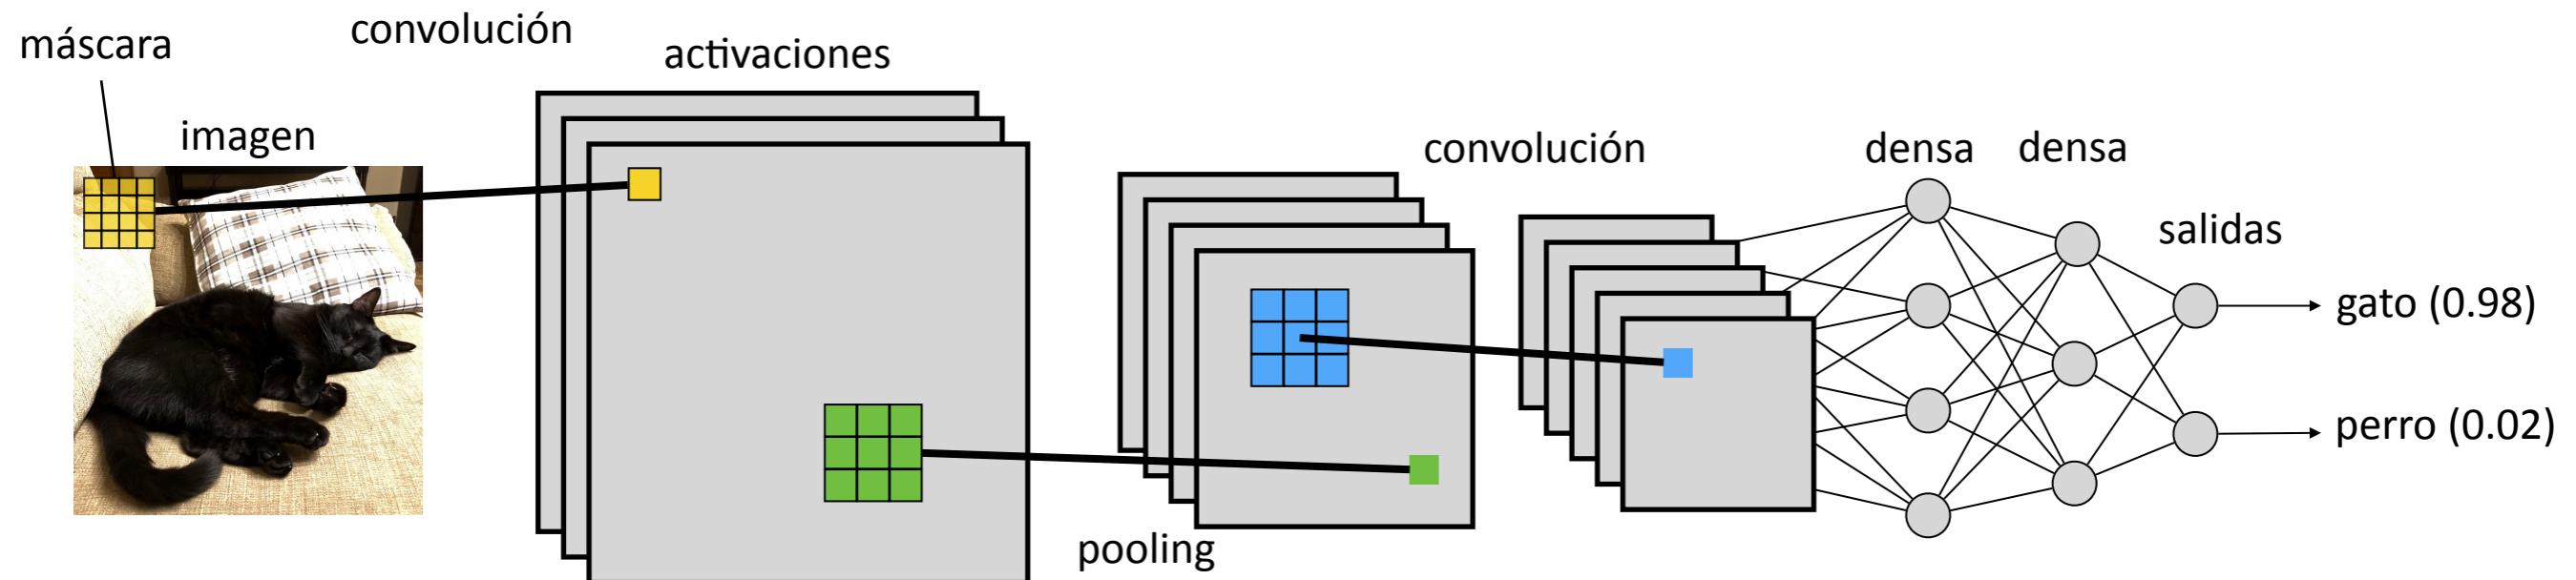
depende de la máscara  
 los pesos de la máscara se “aprenden”

# Avances clave en DL

## Redes convolucionales



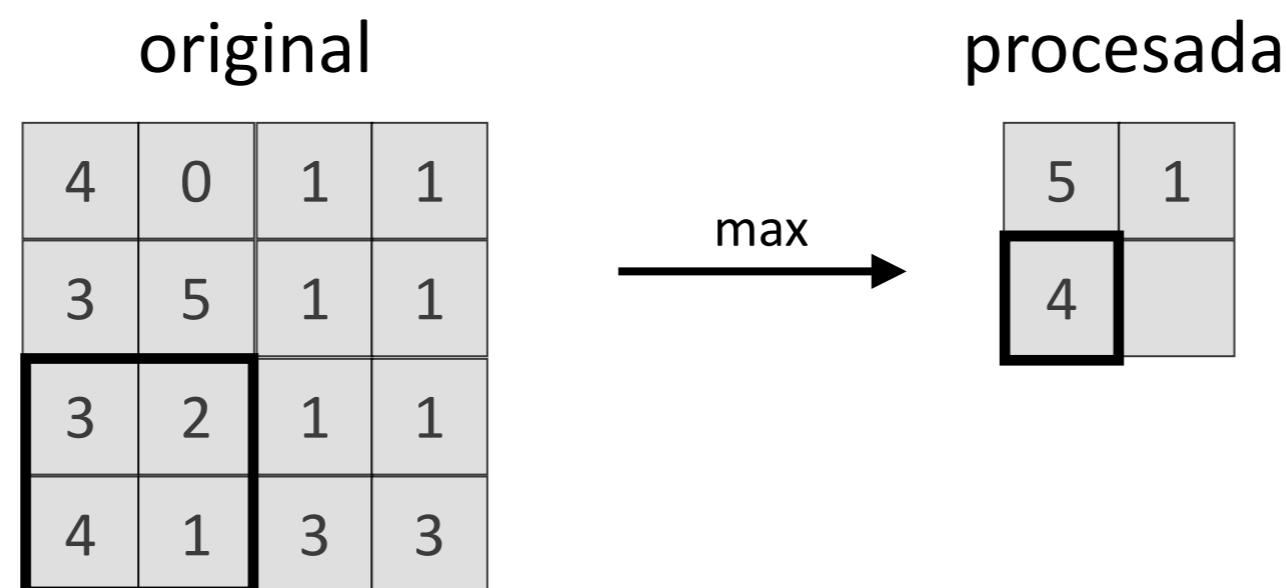
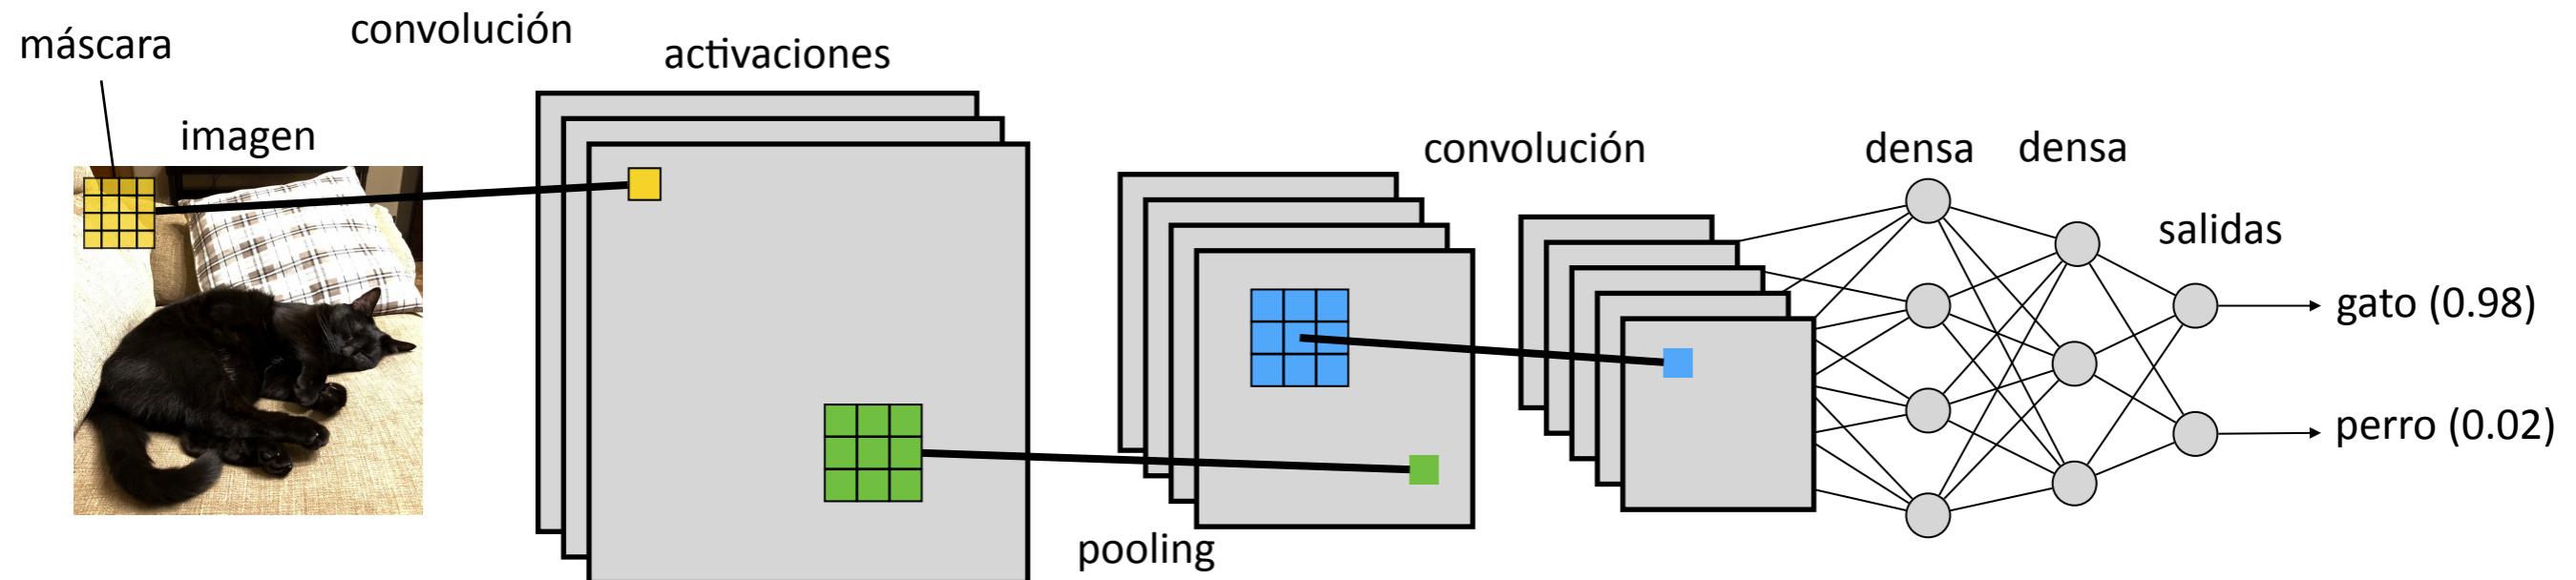
## Operación de pooling



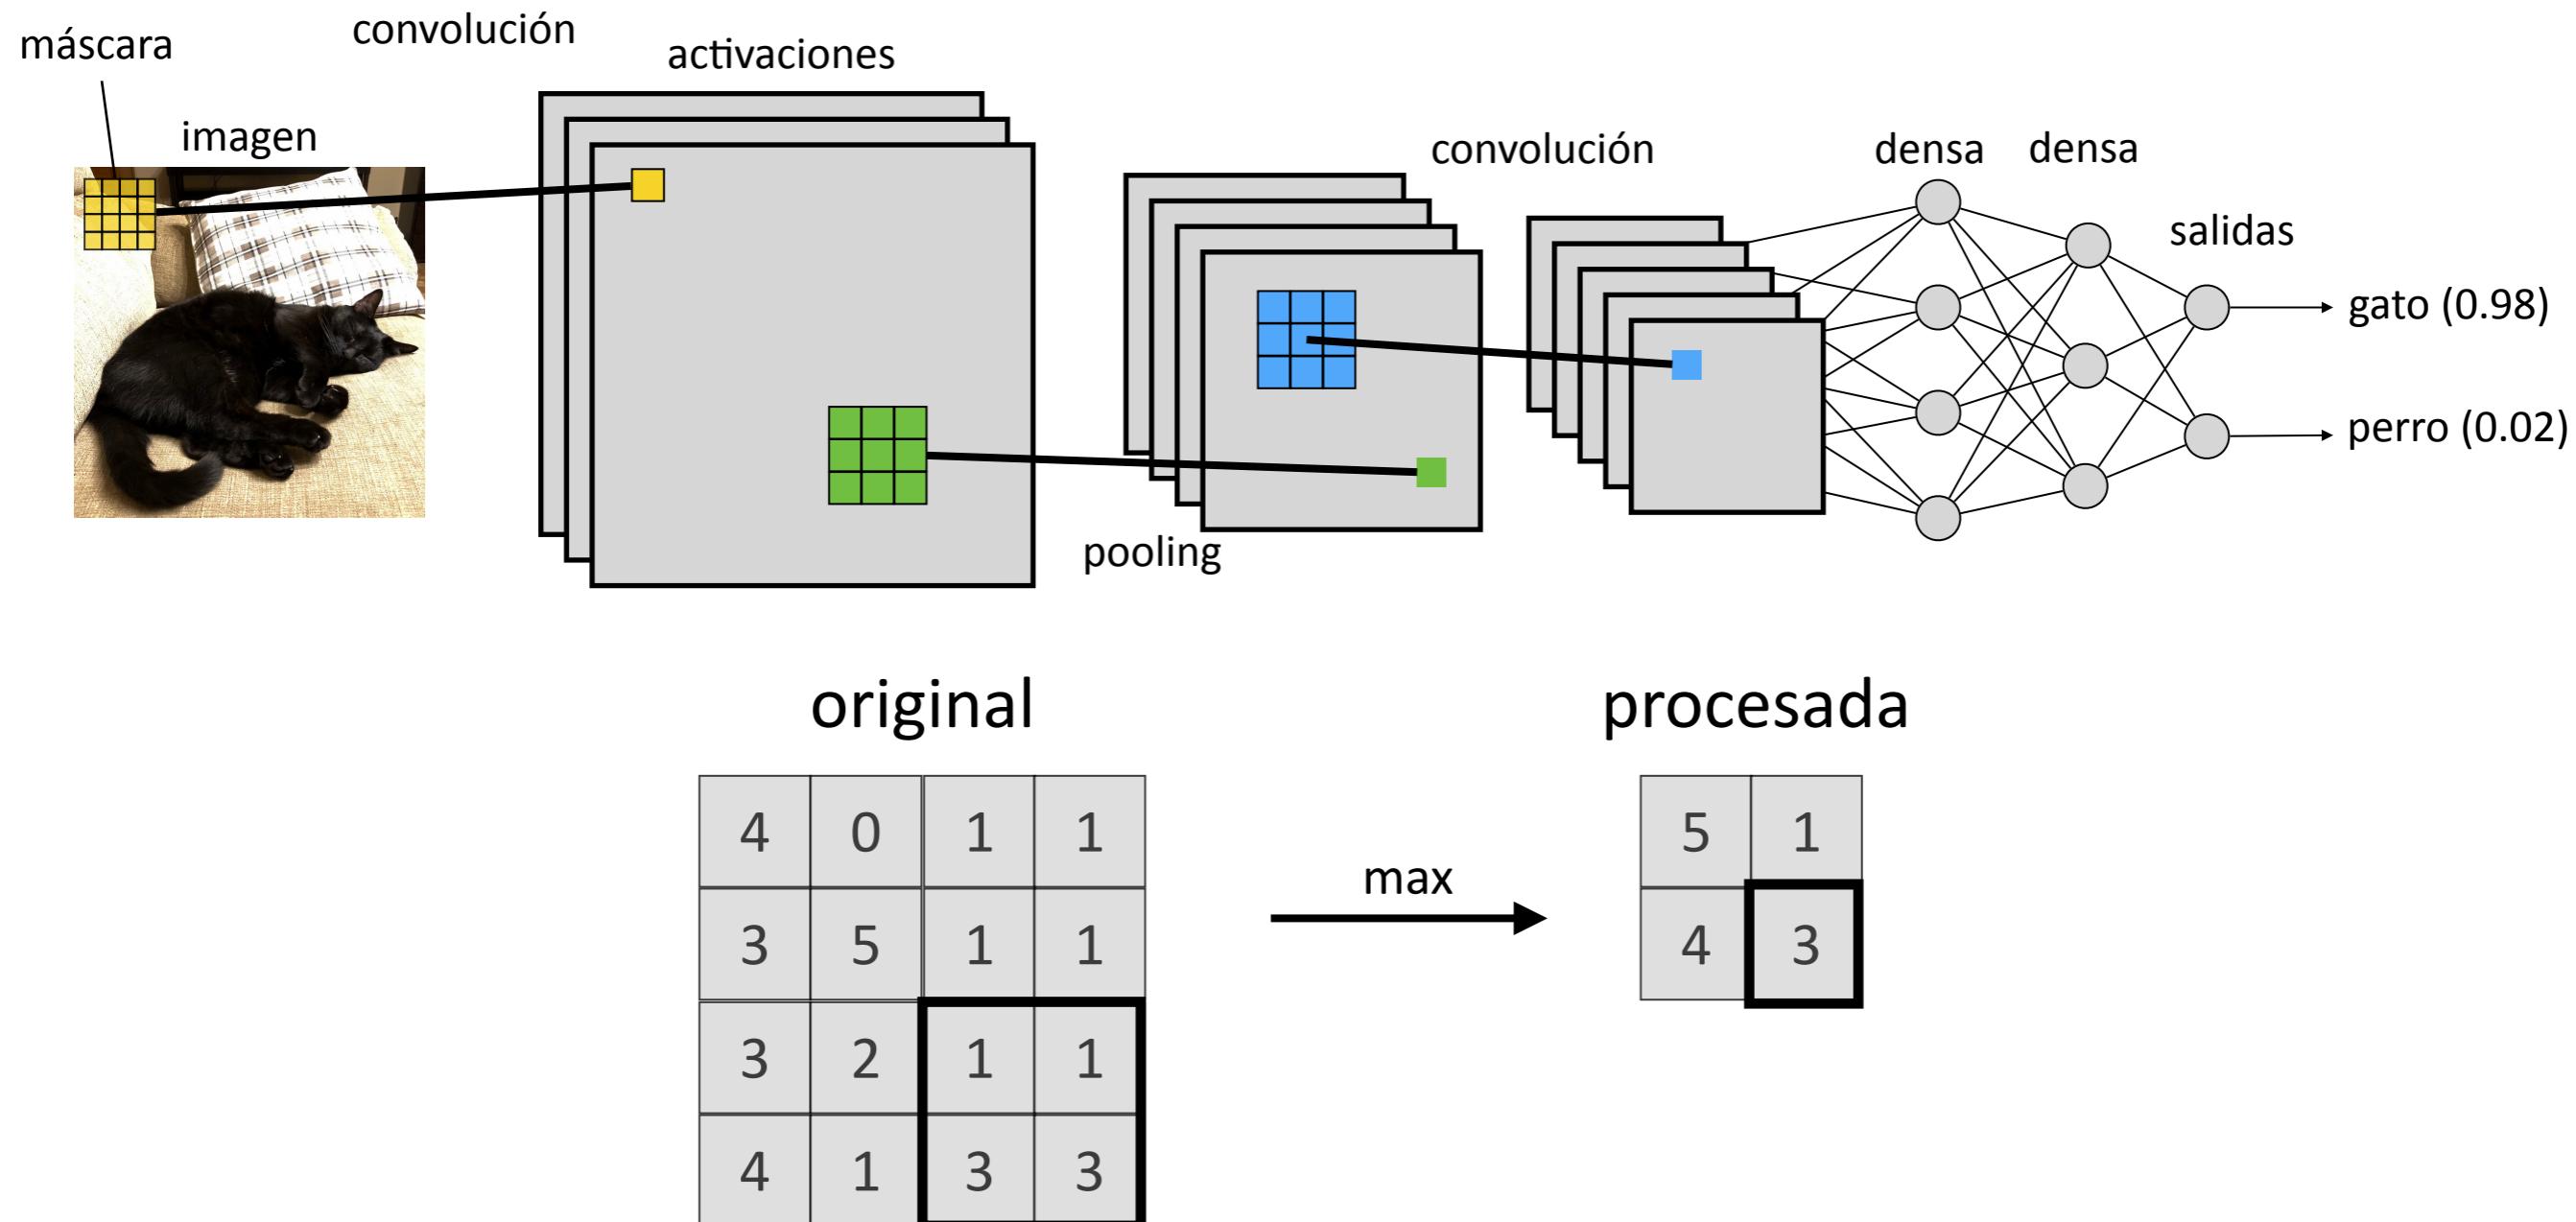
## Operación de pooling

# Avances clave en DL

## Redes convolucionales



## Operación de pooling



## Operación de pooling

La operación de “pooling”  
 permite conseguir invarianza a traslaciones

Reduce el tamaño y los pesos  
 mejora generalización

Cuando leemos,  
la interpretación de cada palabra  
se basa en las anteriores:

el corredor de Gijón llegó el **cuarto** a la meta  
ayer estuve ordenando mi **cuarto**  
no tengo un **cuarto**  
partió el queso y guardó un **cuarto** para mí

Muchos problemas tienen “persistencia”  
requieren información pasada  
para interpretar la presente



procesos  
**con memoria**

Secuencia:

sucesión de valores

un valor puede depender de los anteriores

$$\{\dots \mathbf{x}_{-1}, \mathbf{x}_0, \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n \dots\}$$

## Redes recurrentes

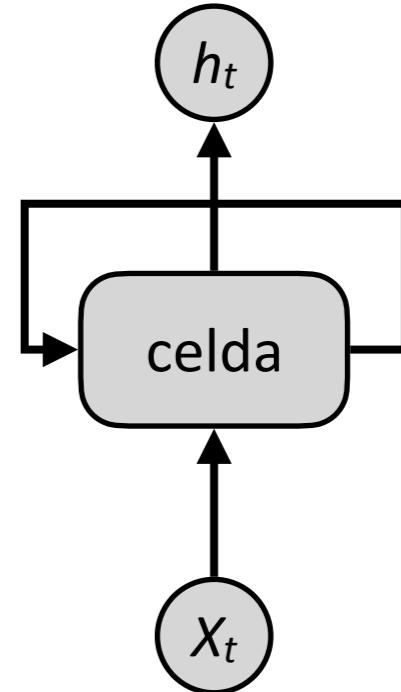
tienen “bucles”,

reprocesan datos

que ellas mismas produjeron



consiguen que  
la información persista



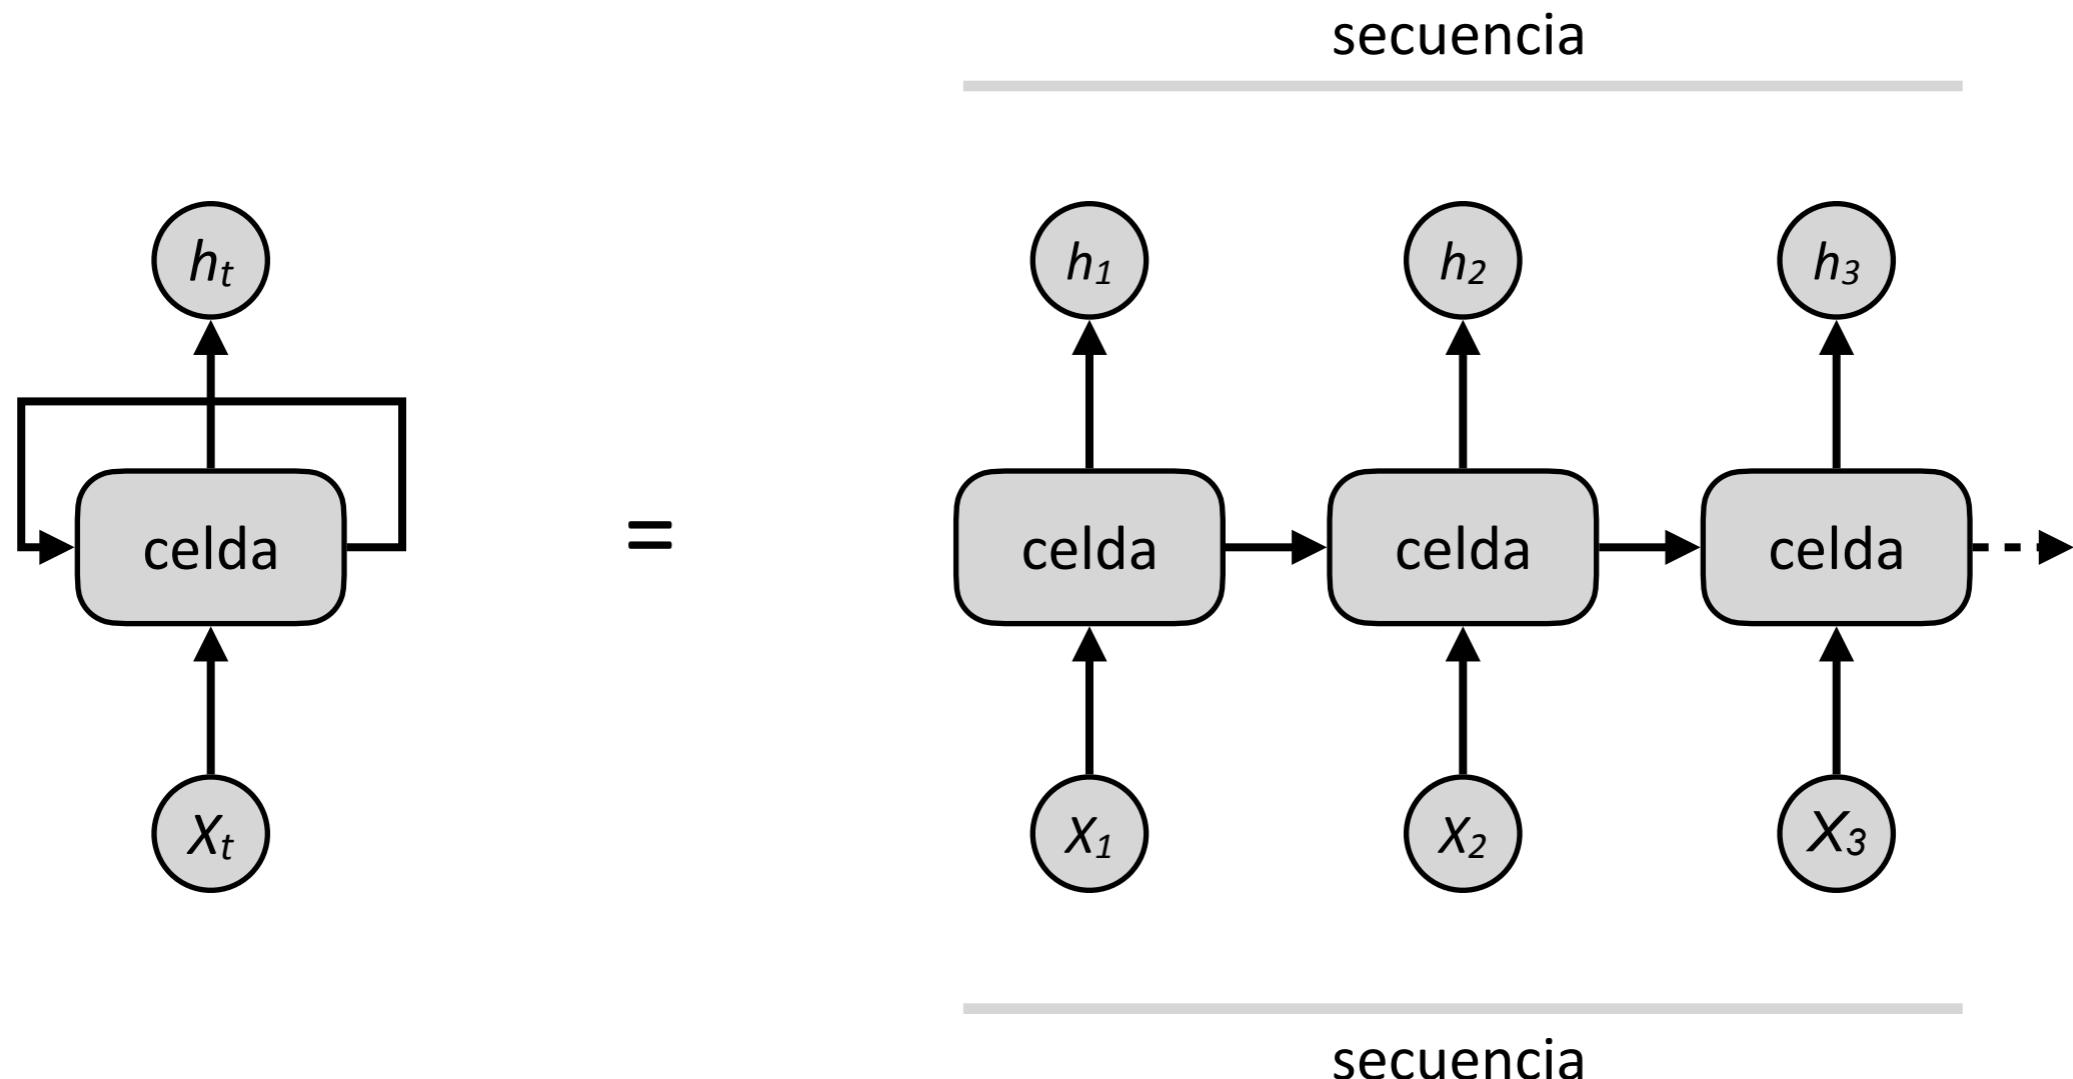
### Referencia

Excelente artículo en el **blog de Colah**:

<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

# Redes recurrentes

Concepto y red recurrente estándar



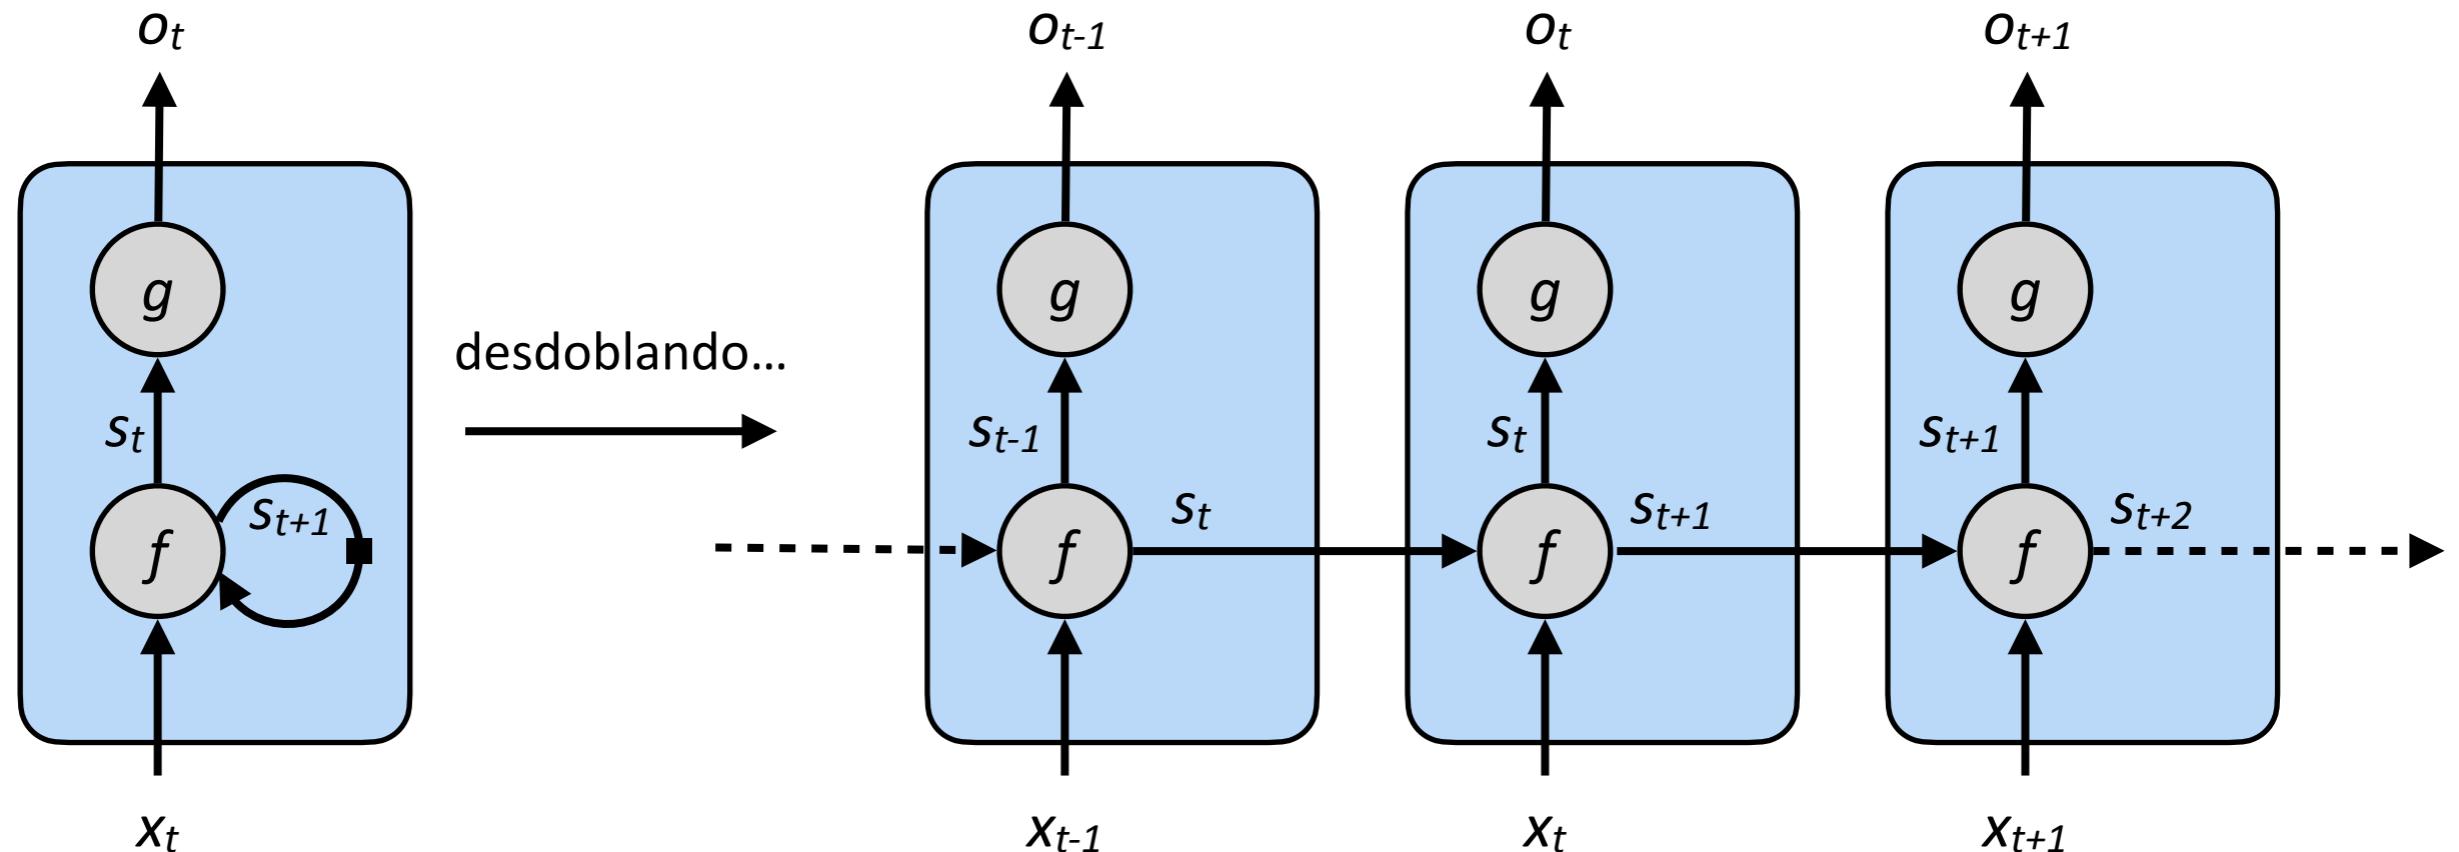
## Referencia

Excelente artículo en el **blog de Colah**:  
<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

### Ecuaciones dinámicas

$$s_{t+1} = f_{W,U}(s_t, x_t)$$

$$o_t = g_V(s_t)$$



**diagrama de bloques**

Leyenda:

$s_t$ : estado interno de la unidad

$x_t$ : entrada

$o_t$ : salida

$W, U$ : parámetros de la función de estado  $f()$

$V$ : parámetros de la función de salida  $g()$

**representación equivalente**

una unidad equivale a una red de profundidad infinita  
tiene memoria

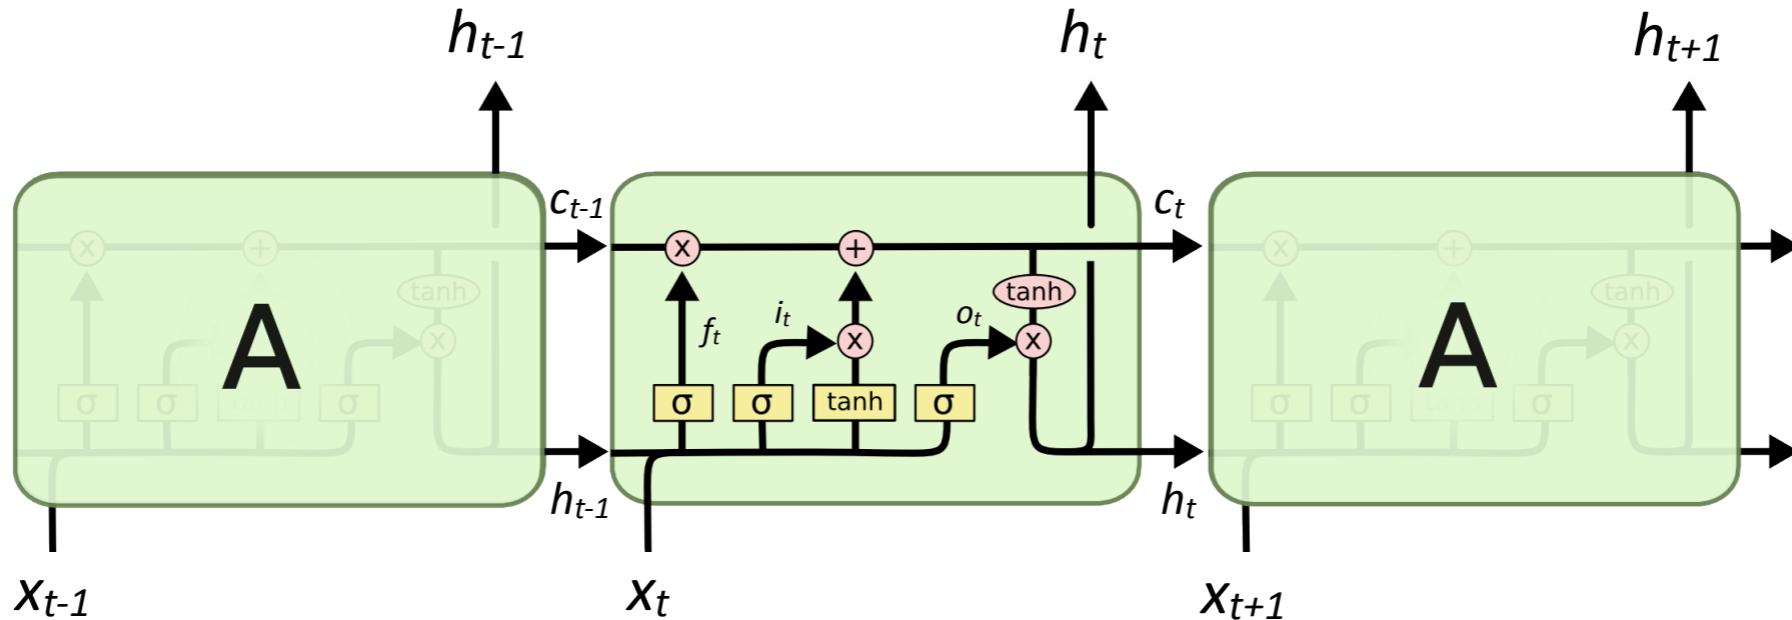
la salida depende del pasado

los pesos  $W, U$  definen una dinámica secuencial

$W, U, V$  son entrenables

# Redes recurrentes

## Long Short-term Memory (LSTM) networks



Fuente: figura adaptada del blog de Colah, <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

### Dinámica y estados internos

$$\begin{aligned} c_t &= f_t c_{t-1} + i_t \tanh(W_c[h_{t-1}, x_t] + b_c) \\ h_t &= o_t \tanh(c_t) \end{aligned}$$

La información (estado) se transfiere hacia la derecha

### Puertas (actúan como moduladores)

$$\begin{aligned} i_t &= \sigma(W_i[h_{t-1}, x_t] + b_i) && \text{entrada} \\ f_t &= \sigma(W_f[h_{t-1}, x_t] + b_f) && \text{olvido} \\ o_t &= \sigma(W_o[h_{t-1}, x_t] + b_o) && \text{salida} \end{aligned}$$

Mediante “puertas” (“gates”) multiplicativas regula la transferencia de información

### Referencia

Excelente artículo en el **blog de Colah**:

<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

Una LSTM tiene tres puertas

- entrada (relevancia de la entrada vs. estado)
- olvido (dinámica interna del estado)
- salida (qué parte dejamos fluir hacia la siguiente)

### Elementos de una LSTM

#### Celda

- El estado de la celda se almacena en el vector  $c_t$
- Es como una cinta transportadora
- Transporta información útil entre etapas
- la LSTM añade o quita información mediante "puertas"

#### Puertas

- Estructuras para dejar fluir o no la información
- Funcionan como grifos: cierran o abren paso a valores
- Una LSTM tiene tres puertas: forget, input, output

#### Puerta "forget"

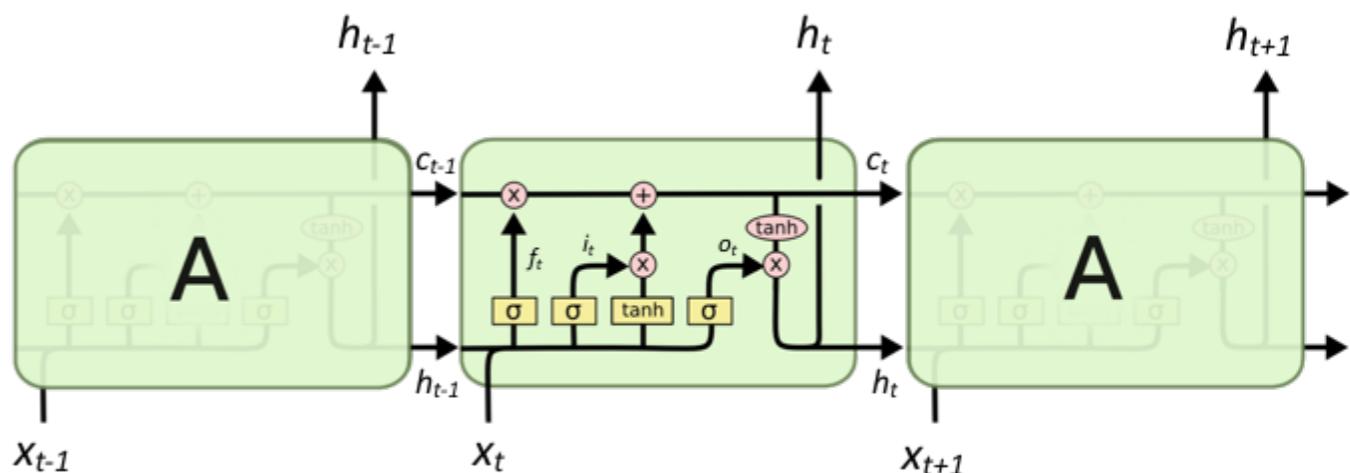
- decide cuánta información se conserva en la celda
- un "1" implica "conservar esto al 100%"
- un "0" implica "olvidarlo completamente"

#### Puerta "input"

- decide qué información nueva (de  $x_t$ ) se añade a la celda
- la tanh genera valores candidatos para cambiarla
- la sigmoide (grifo) decide qué valores candidatos lo hacen

#### Puerta "output"

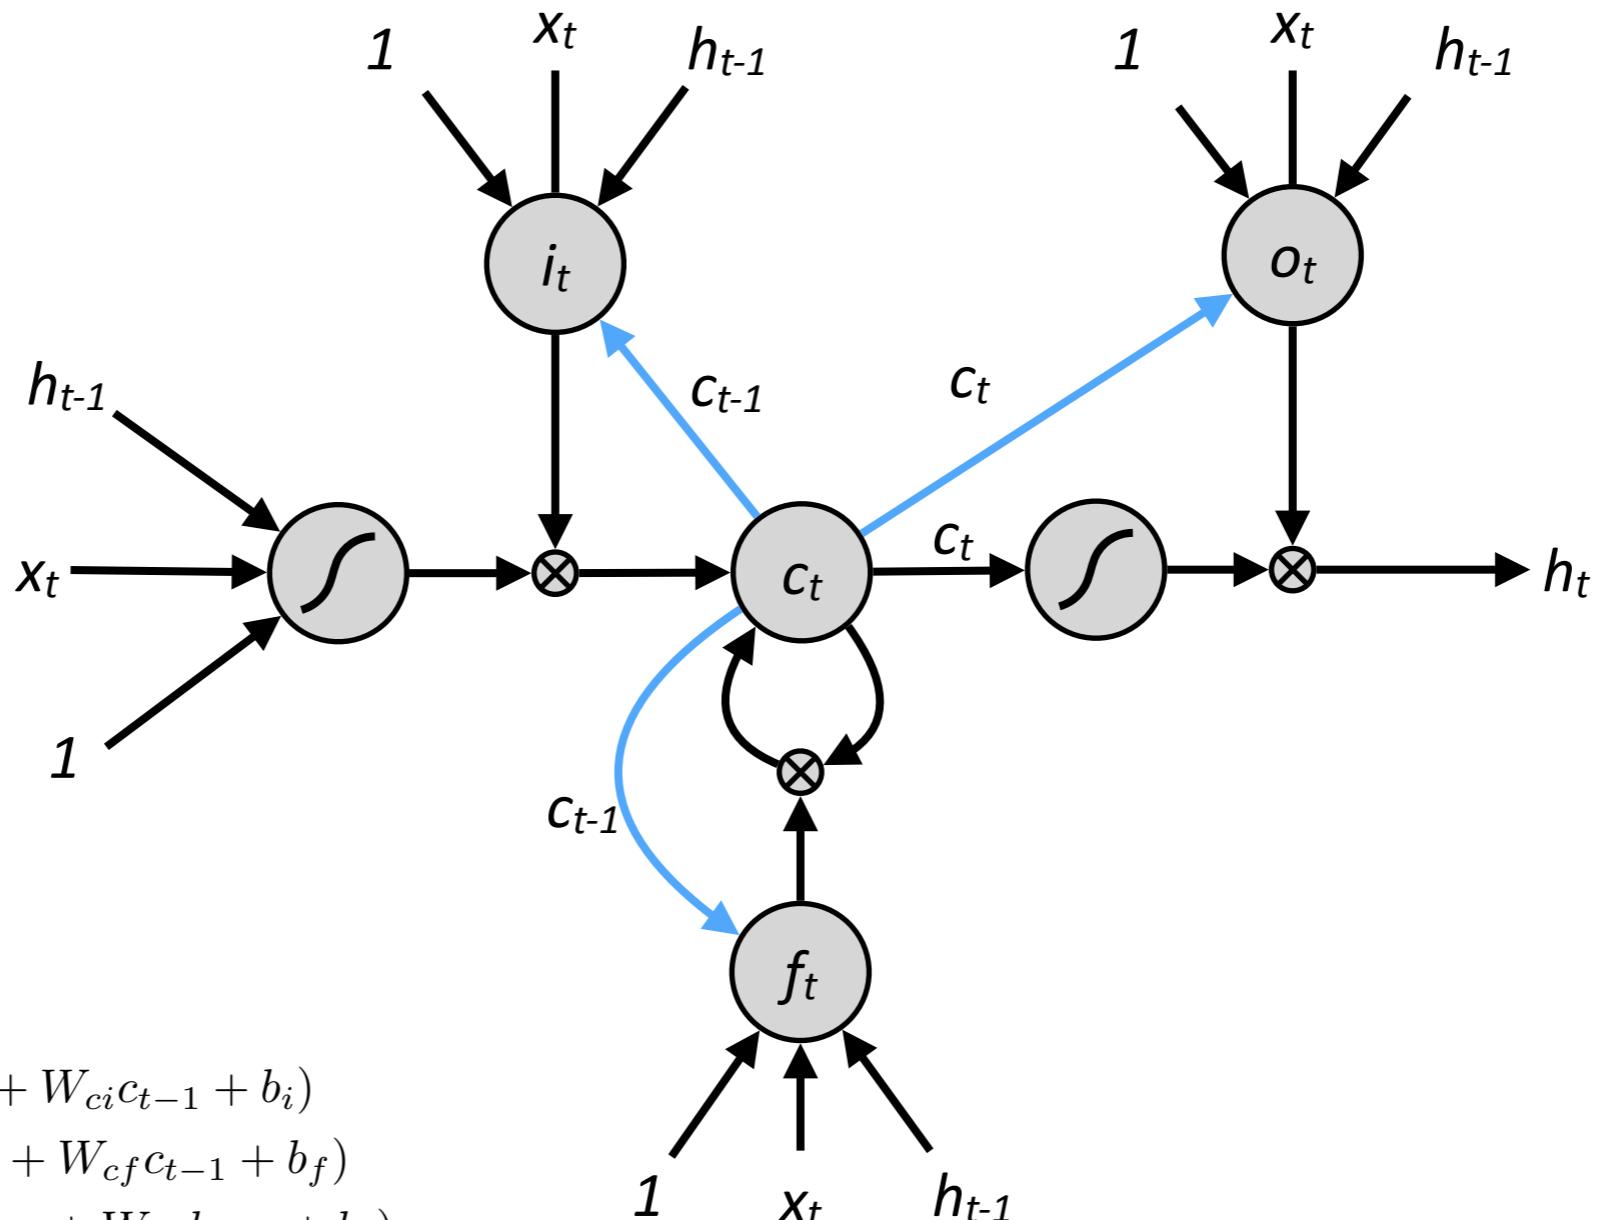
- la tanh transforma valores de  $c_t$  en -1 a 1
- la sigmoide (grifo) decide qué información de  $c_t$  sale a  $h_t$



Fuente: figura adaptada del blog de Colah, <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

# Redes recurrentes

## Variante de LSTM con conexiones “peephole”



$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f)$$

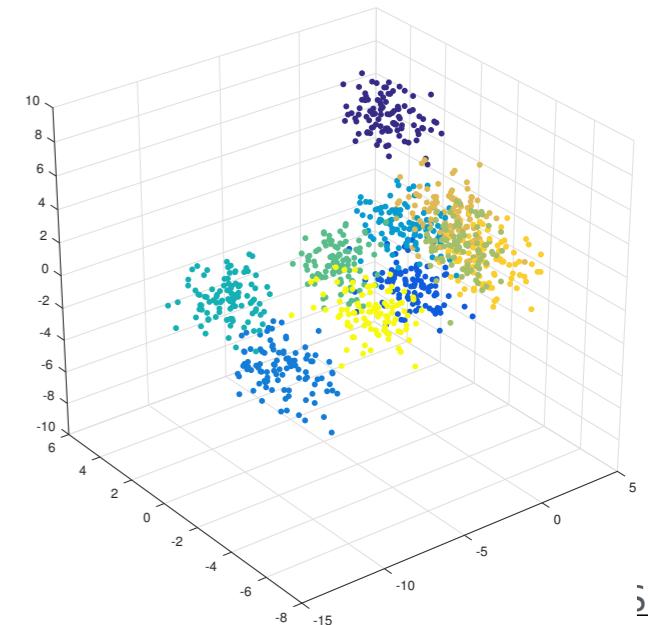
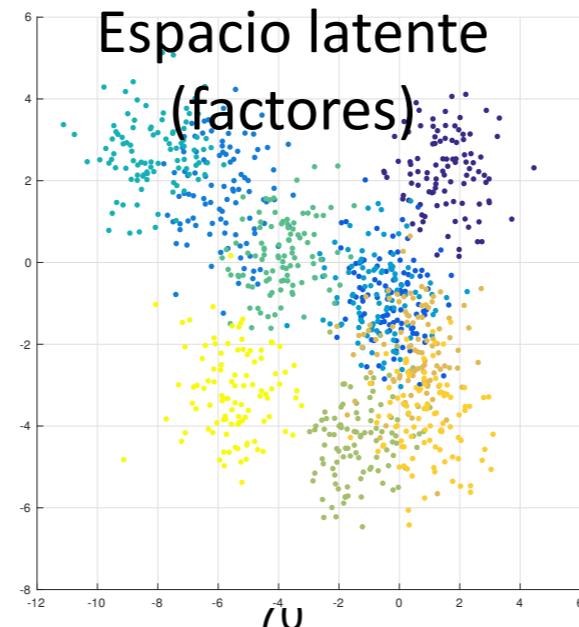
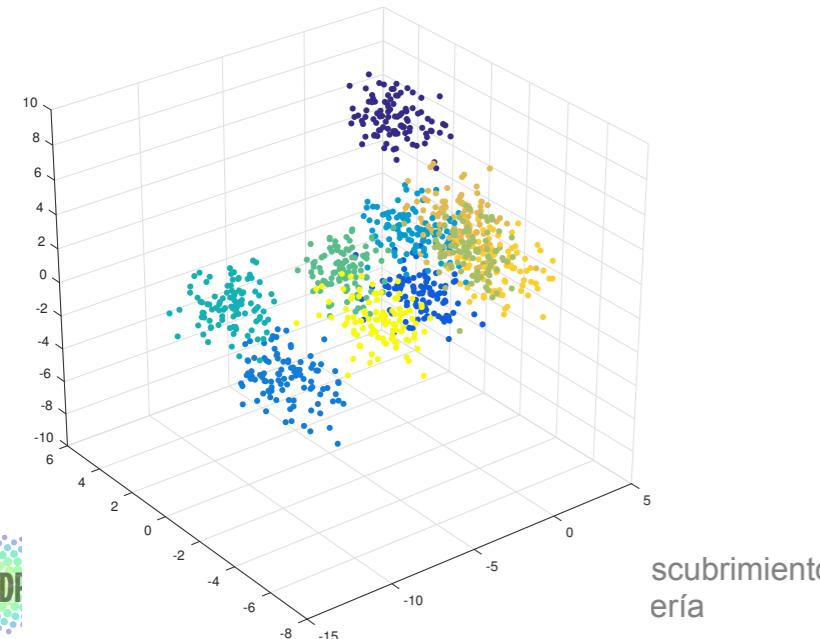
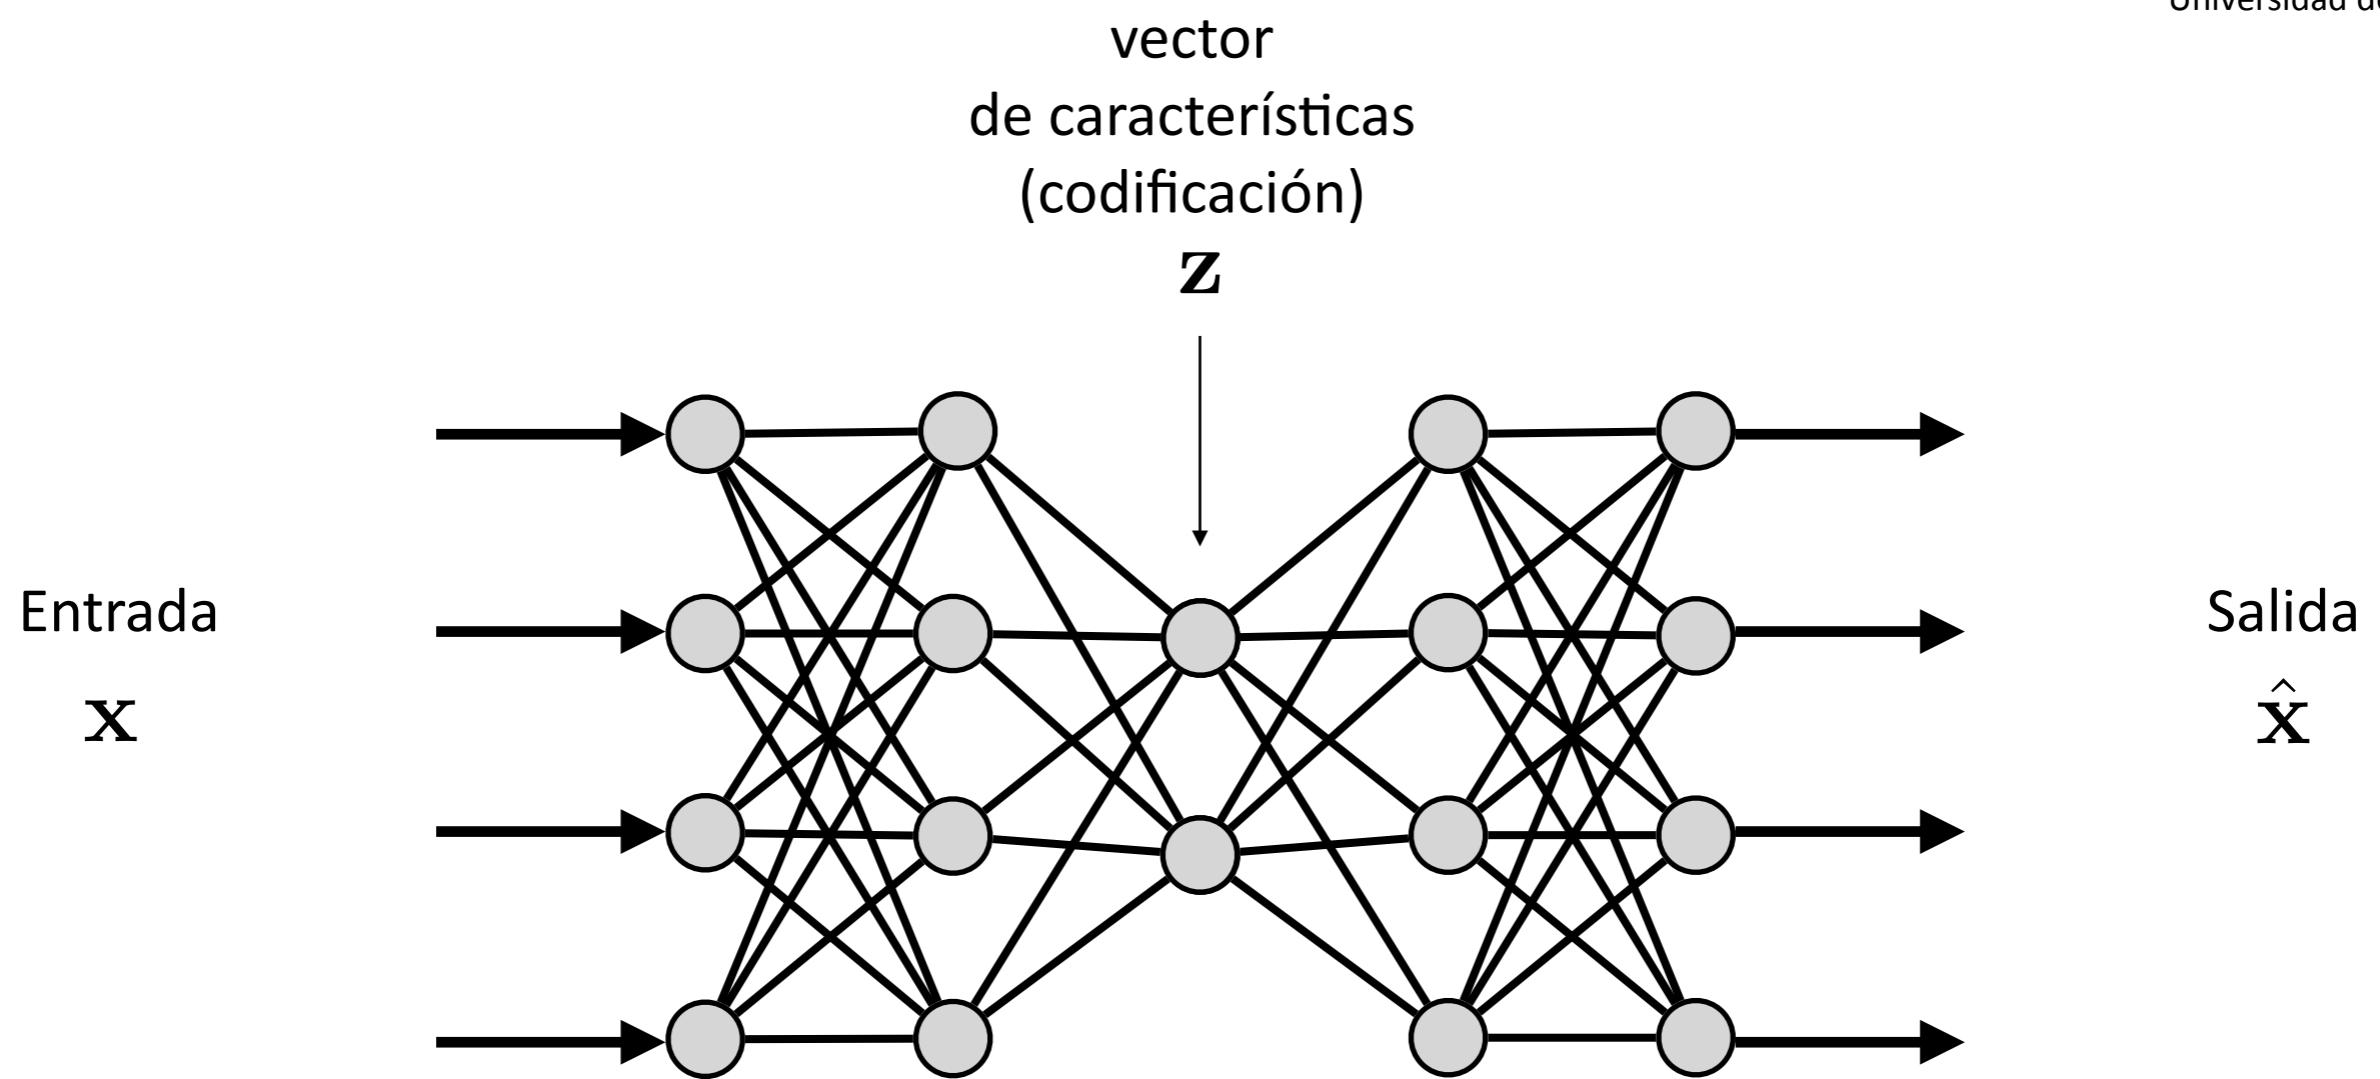
$$c_t = f_t c_{t-1} + i_t \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_o)$$

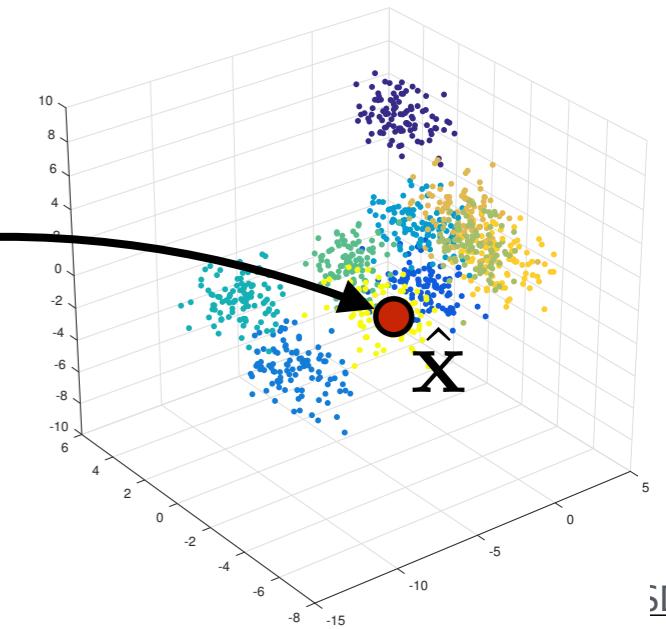
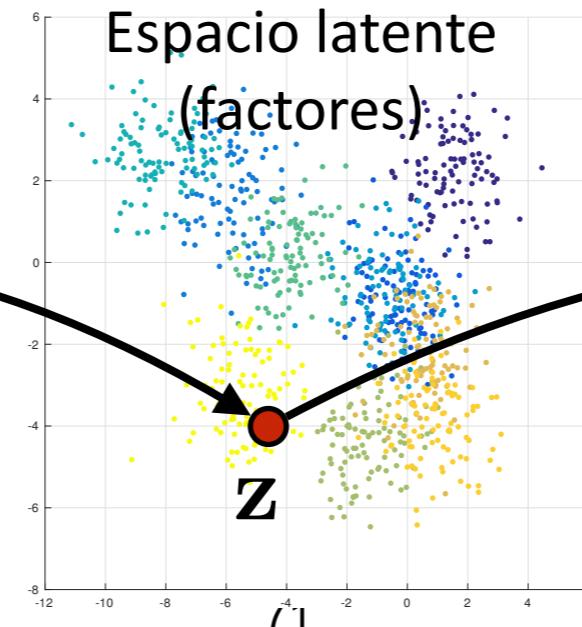
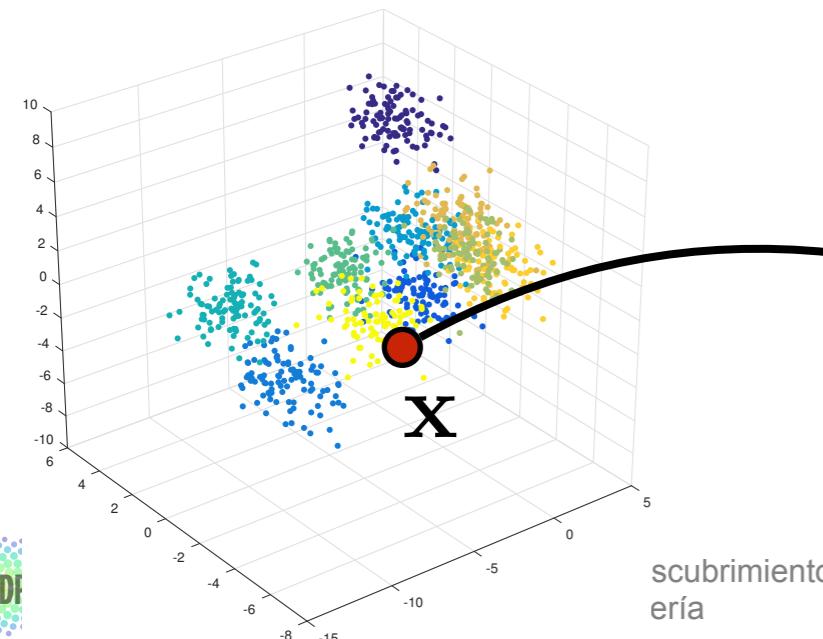
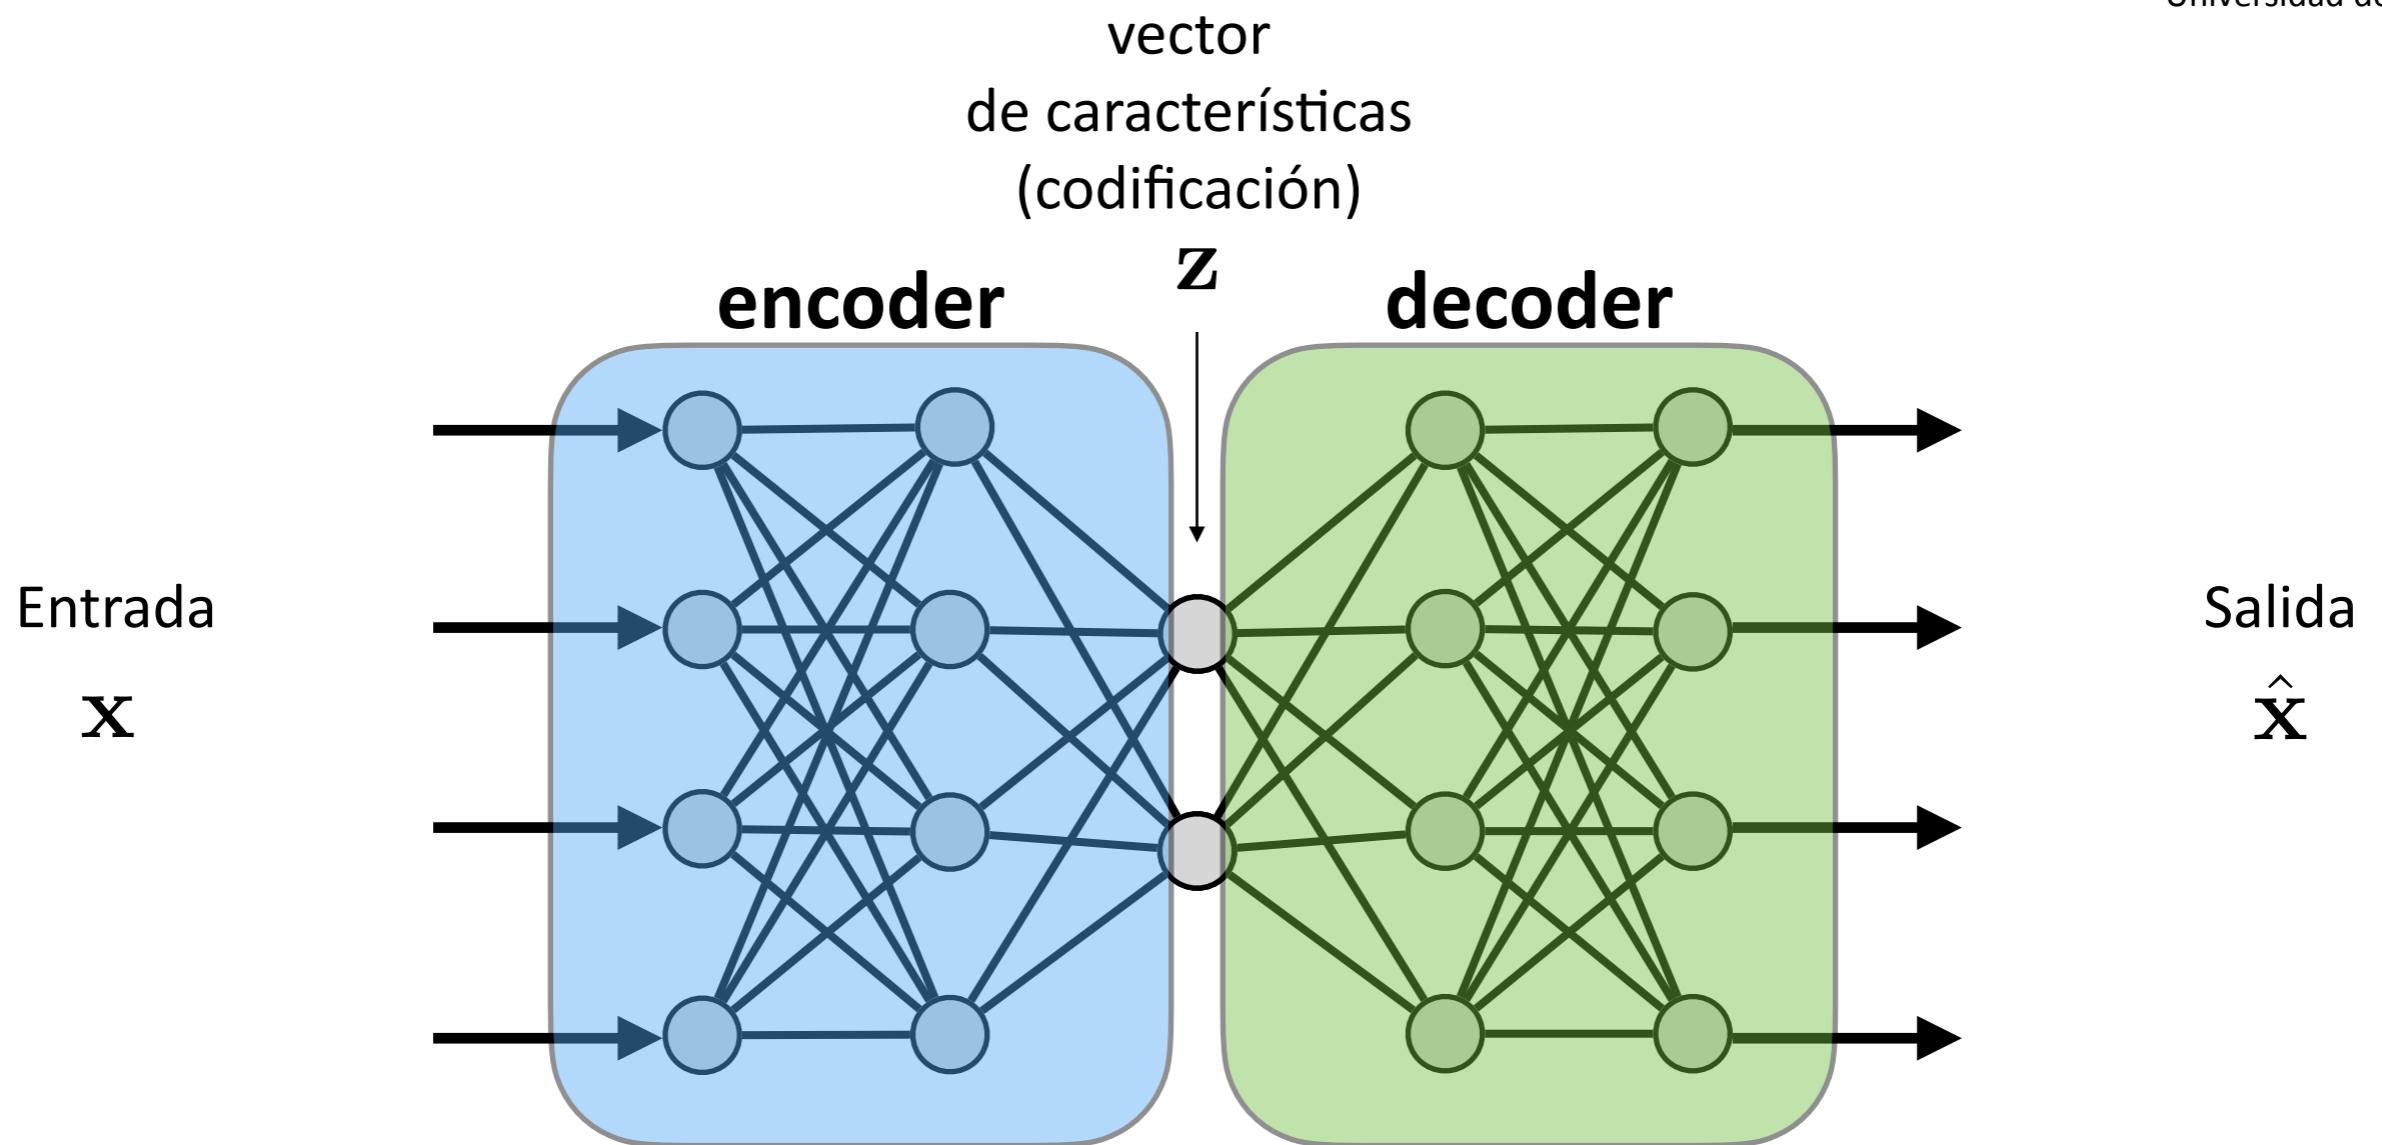
$$h_t = o_t \tanh(c_t)$$

**Referencia:** A. Graves, N. Jaitly, A. Mohamed. **Hybrid Speech Recognition with Deep Bidirectional LSTM**

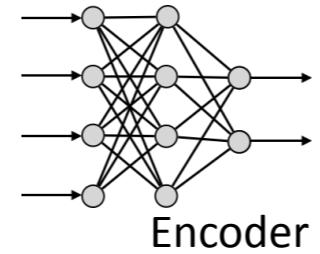
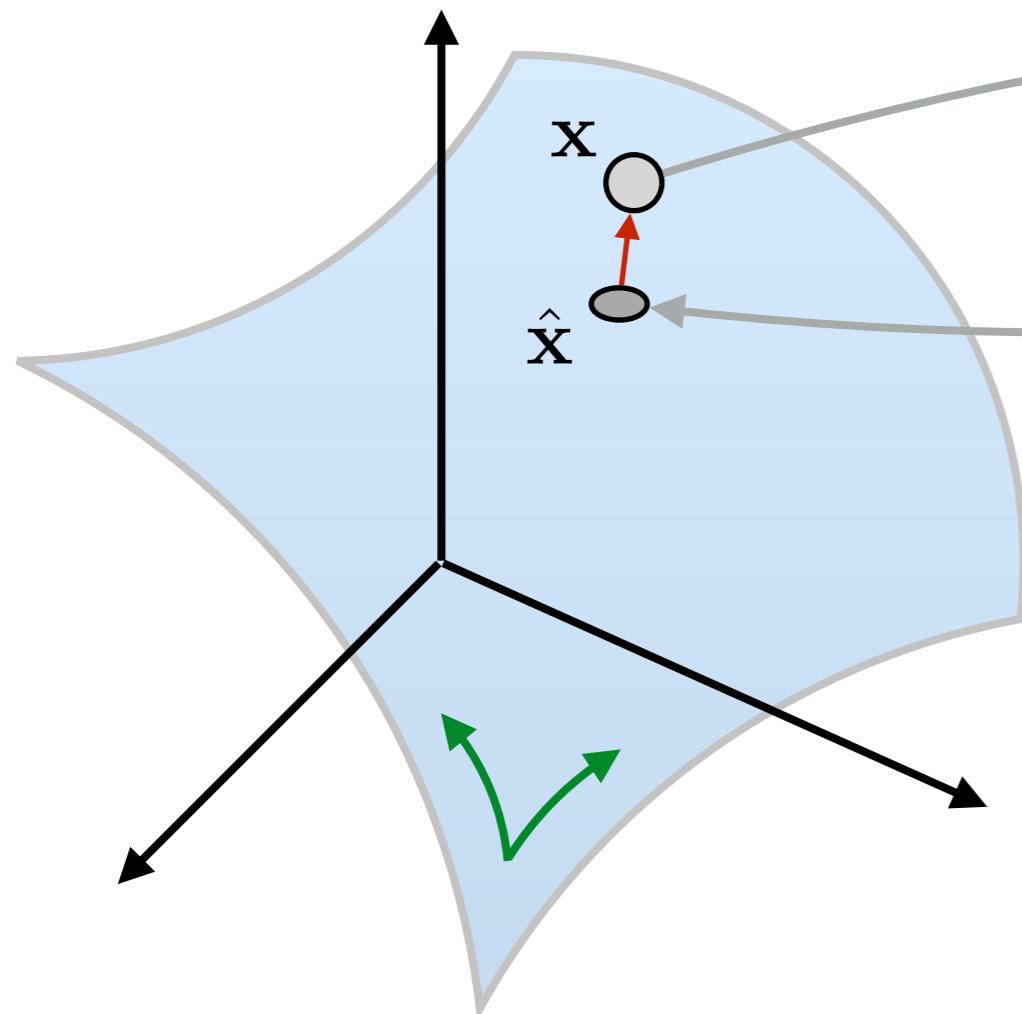
# Deep autoencoders



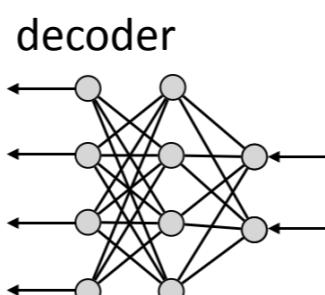
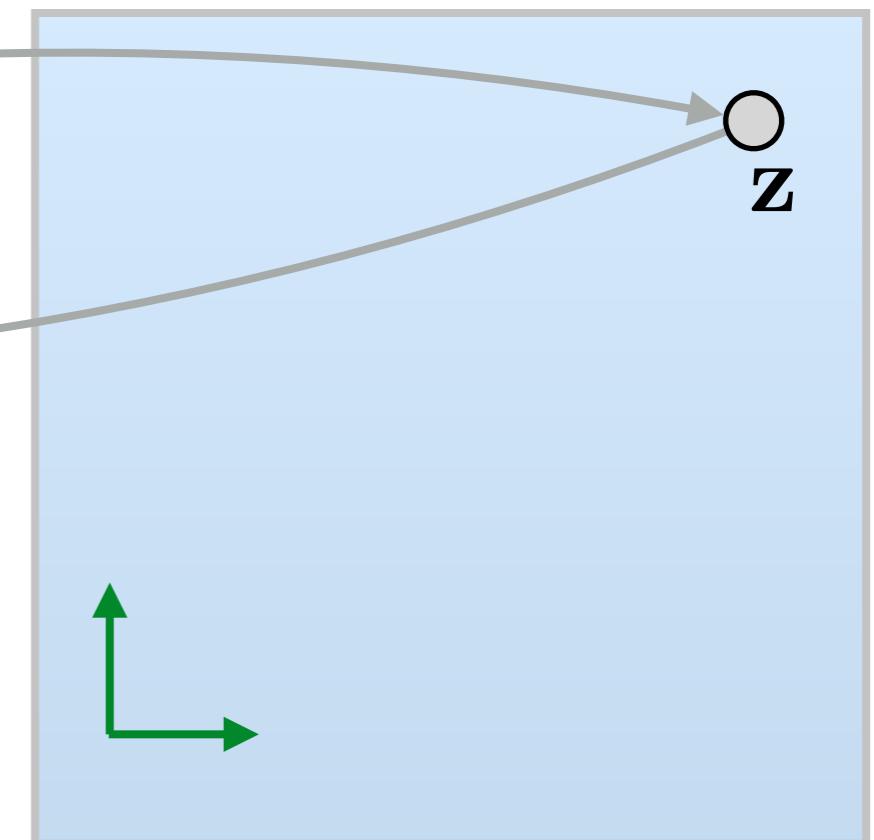
# Deep autoencoders



**Espacio de datos**



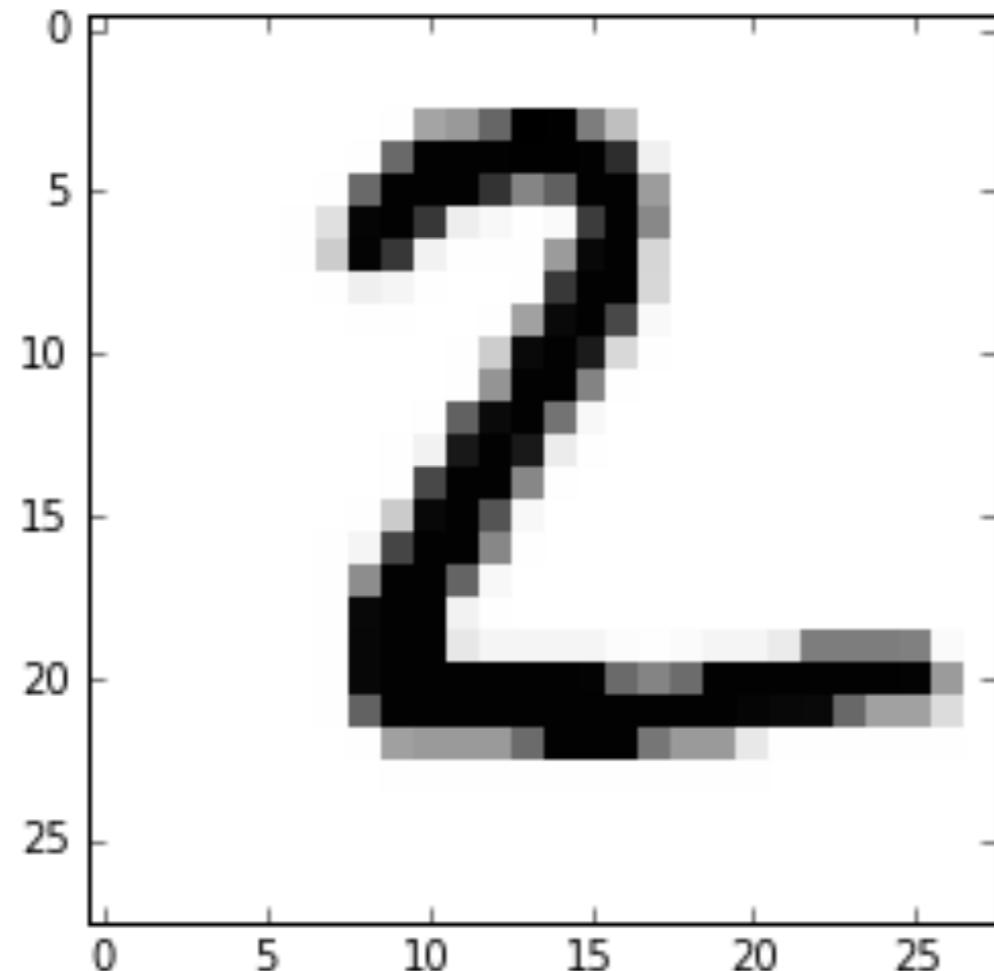
**Espacio latente**



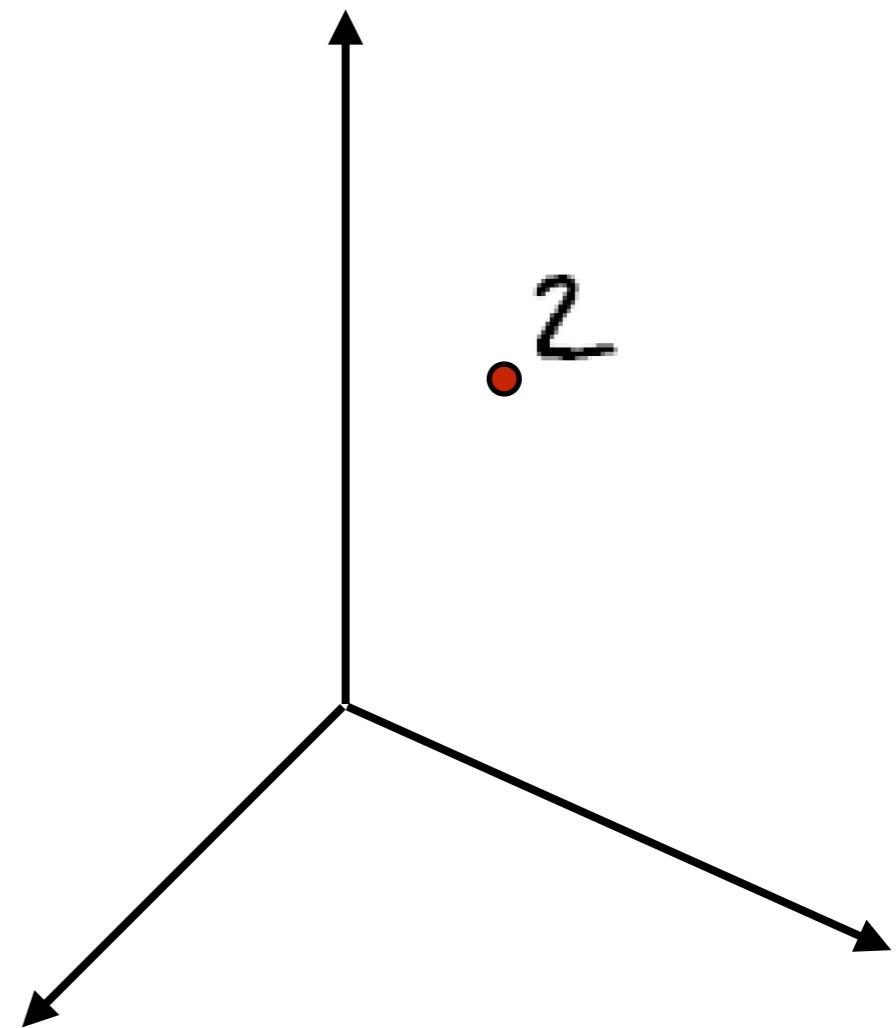
# Ejemplo autoencoders

## proyección de imágenes MNIST: dígitos manuscritos

imágenes de 28x28 px



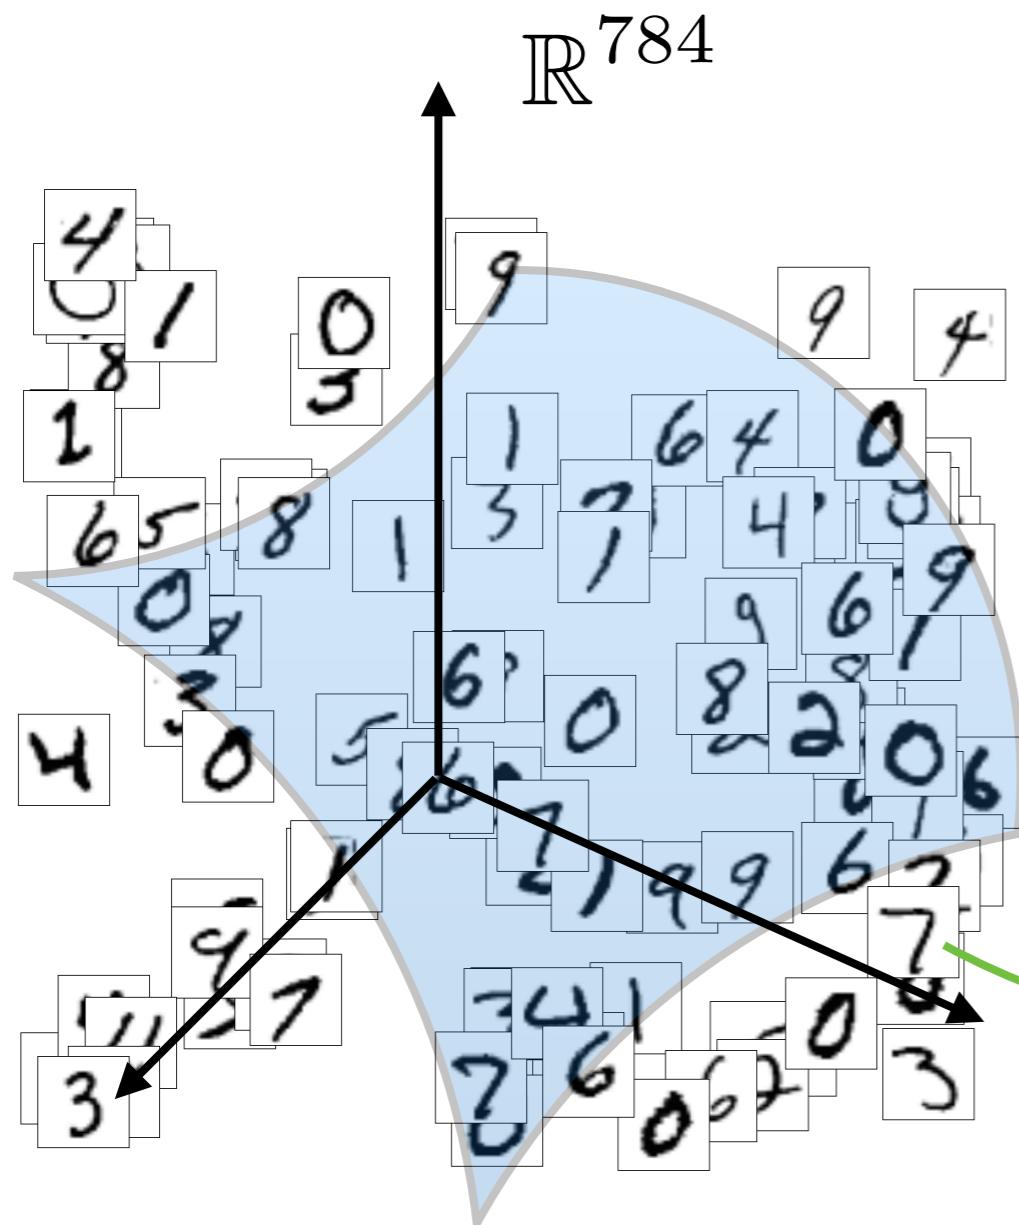
$28 \times 28 = 784$  dimensiones



# Ejemplo autoencoders

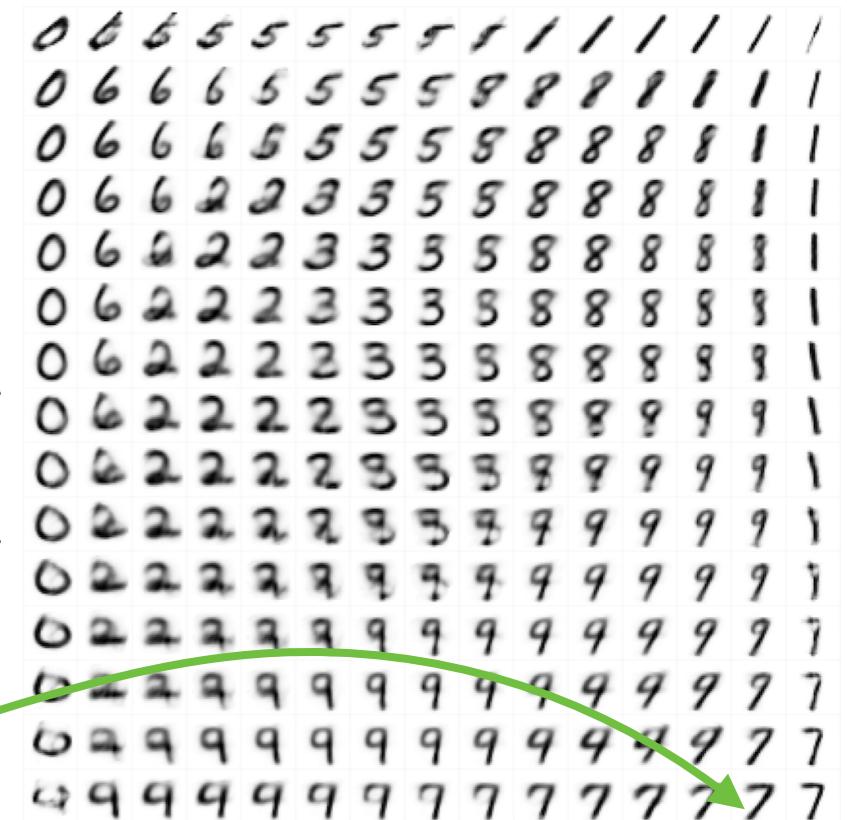
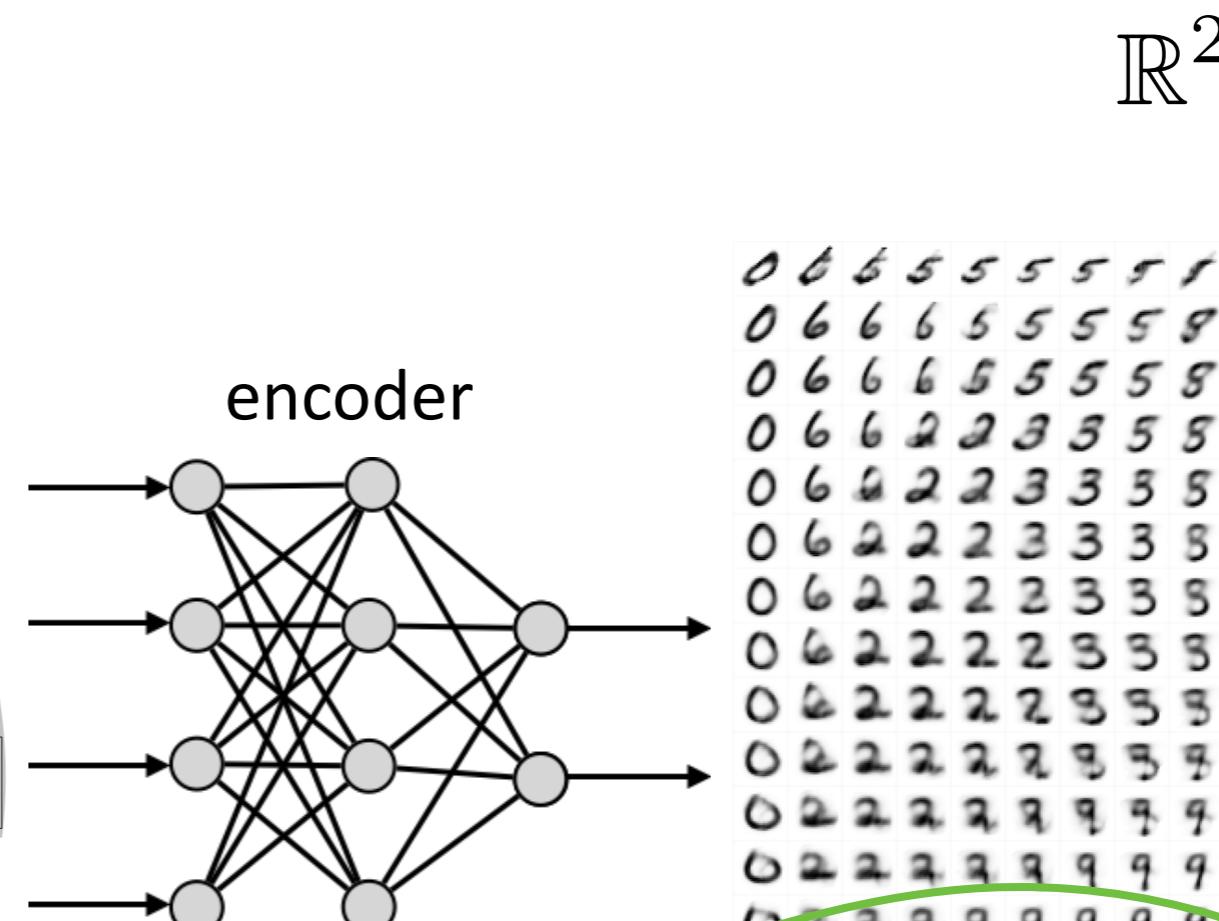
proyección de imágenes MNIST: dígitos manuscritos

**Espacio de datos**  
(alta dimensionalidad)



dataset MNIST:  
60000 dígitos manuscritos

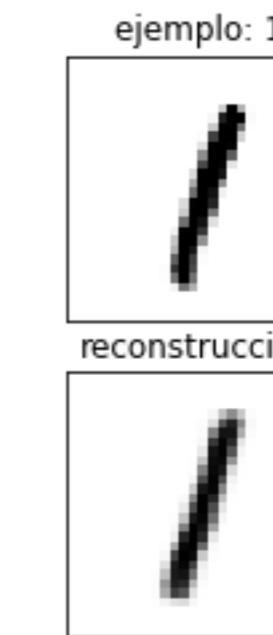
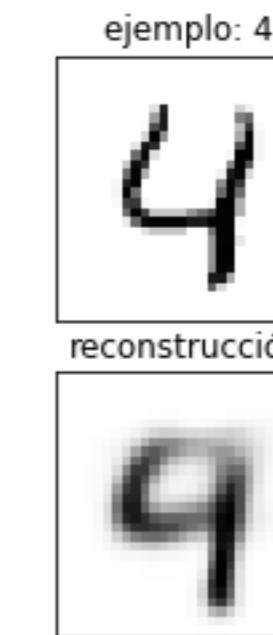
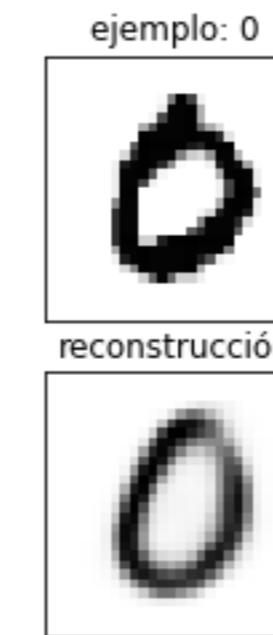
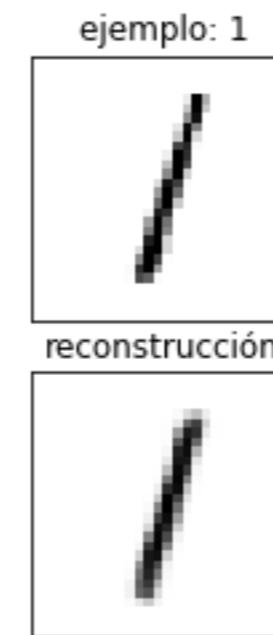
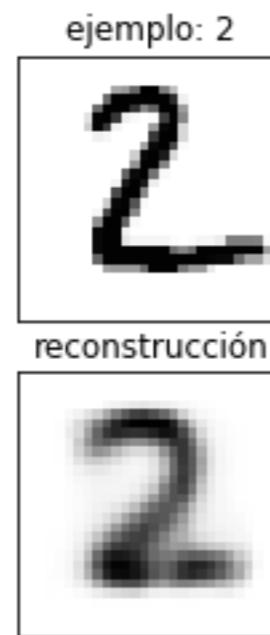
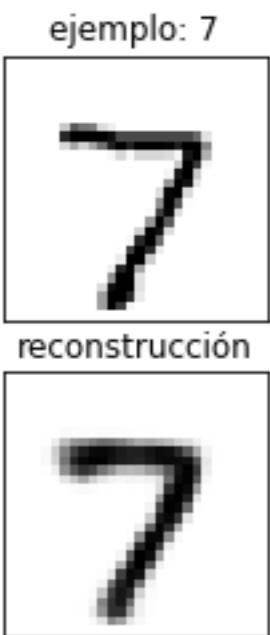
**Espacio latente**  
(baja dimensionalidad)



Hemos creado  
un “mapa visual”  
de los datos

### Reconstrucción de datos

$\mathbf{x}$

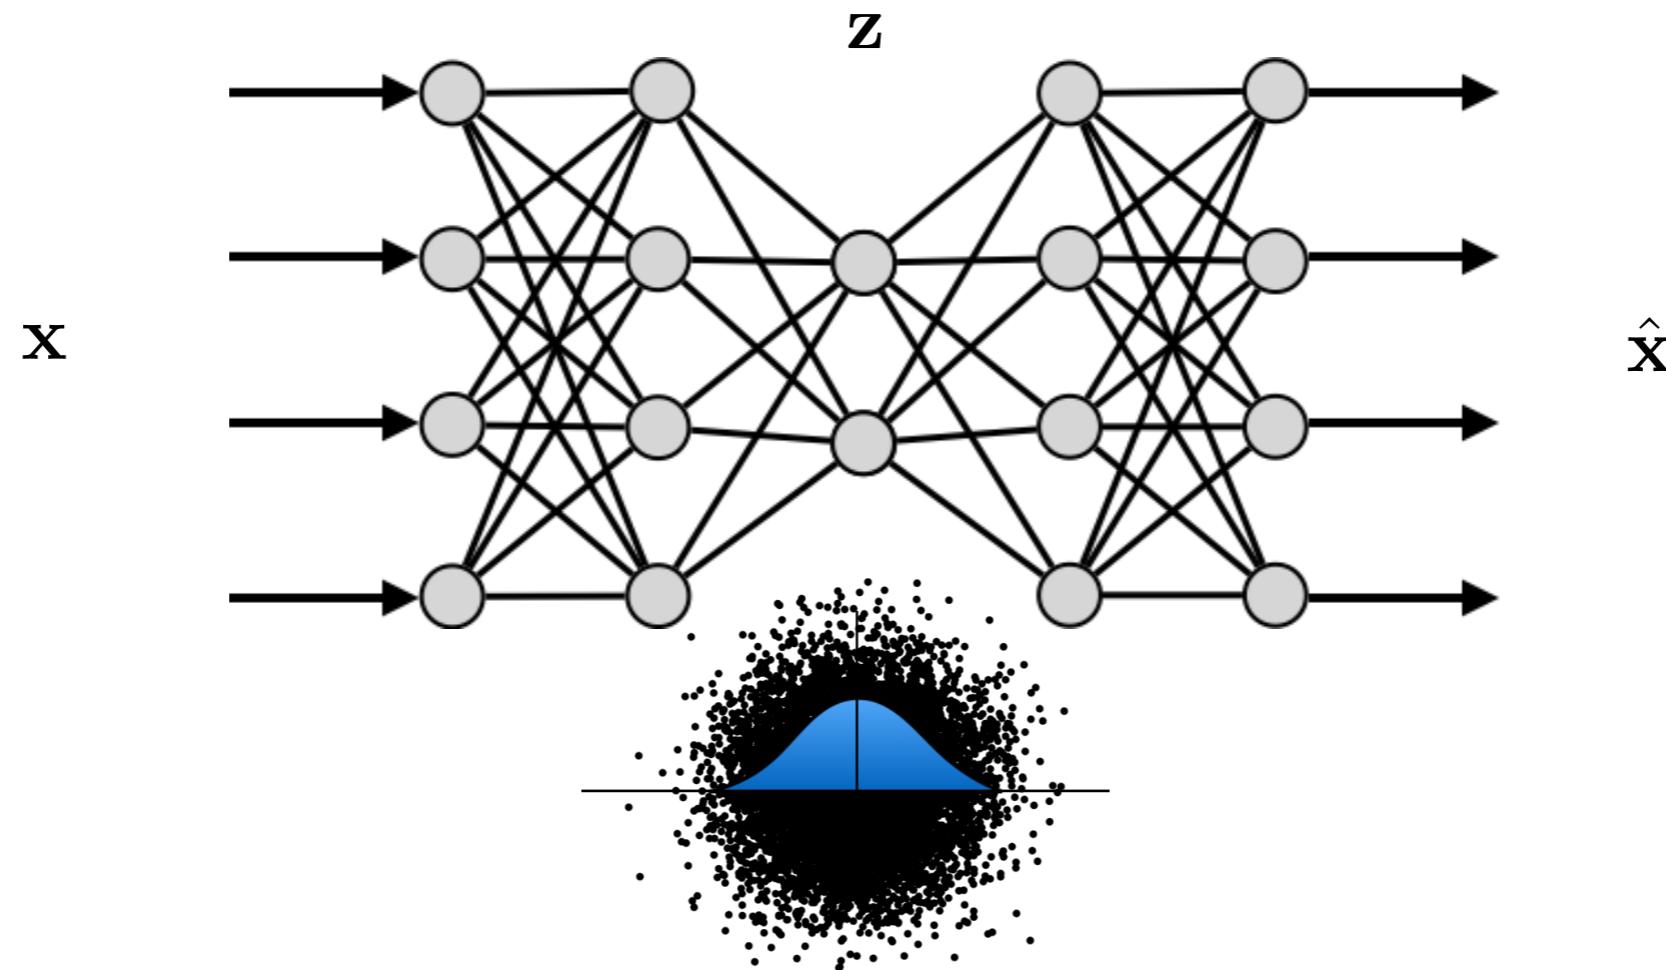


- reconstruir ejemplos corruptos con ruido
- generar ejemplos “creíbles”
- detección de fallos / detección de fraude → residuos     $r = \|\mathbf{x} - \hat{\mathbf{x}}\|^2$

# Variantes de Autoencoders

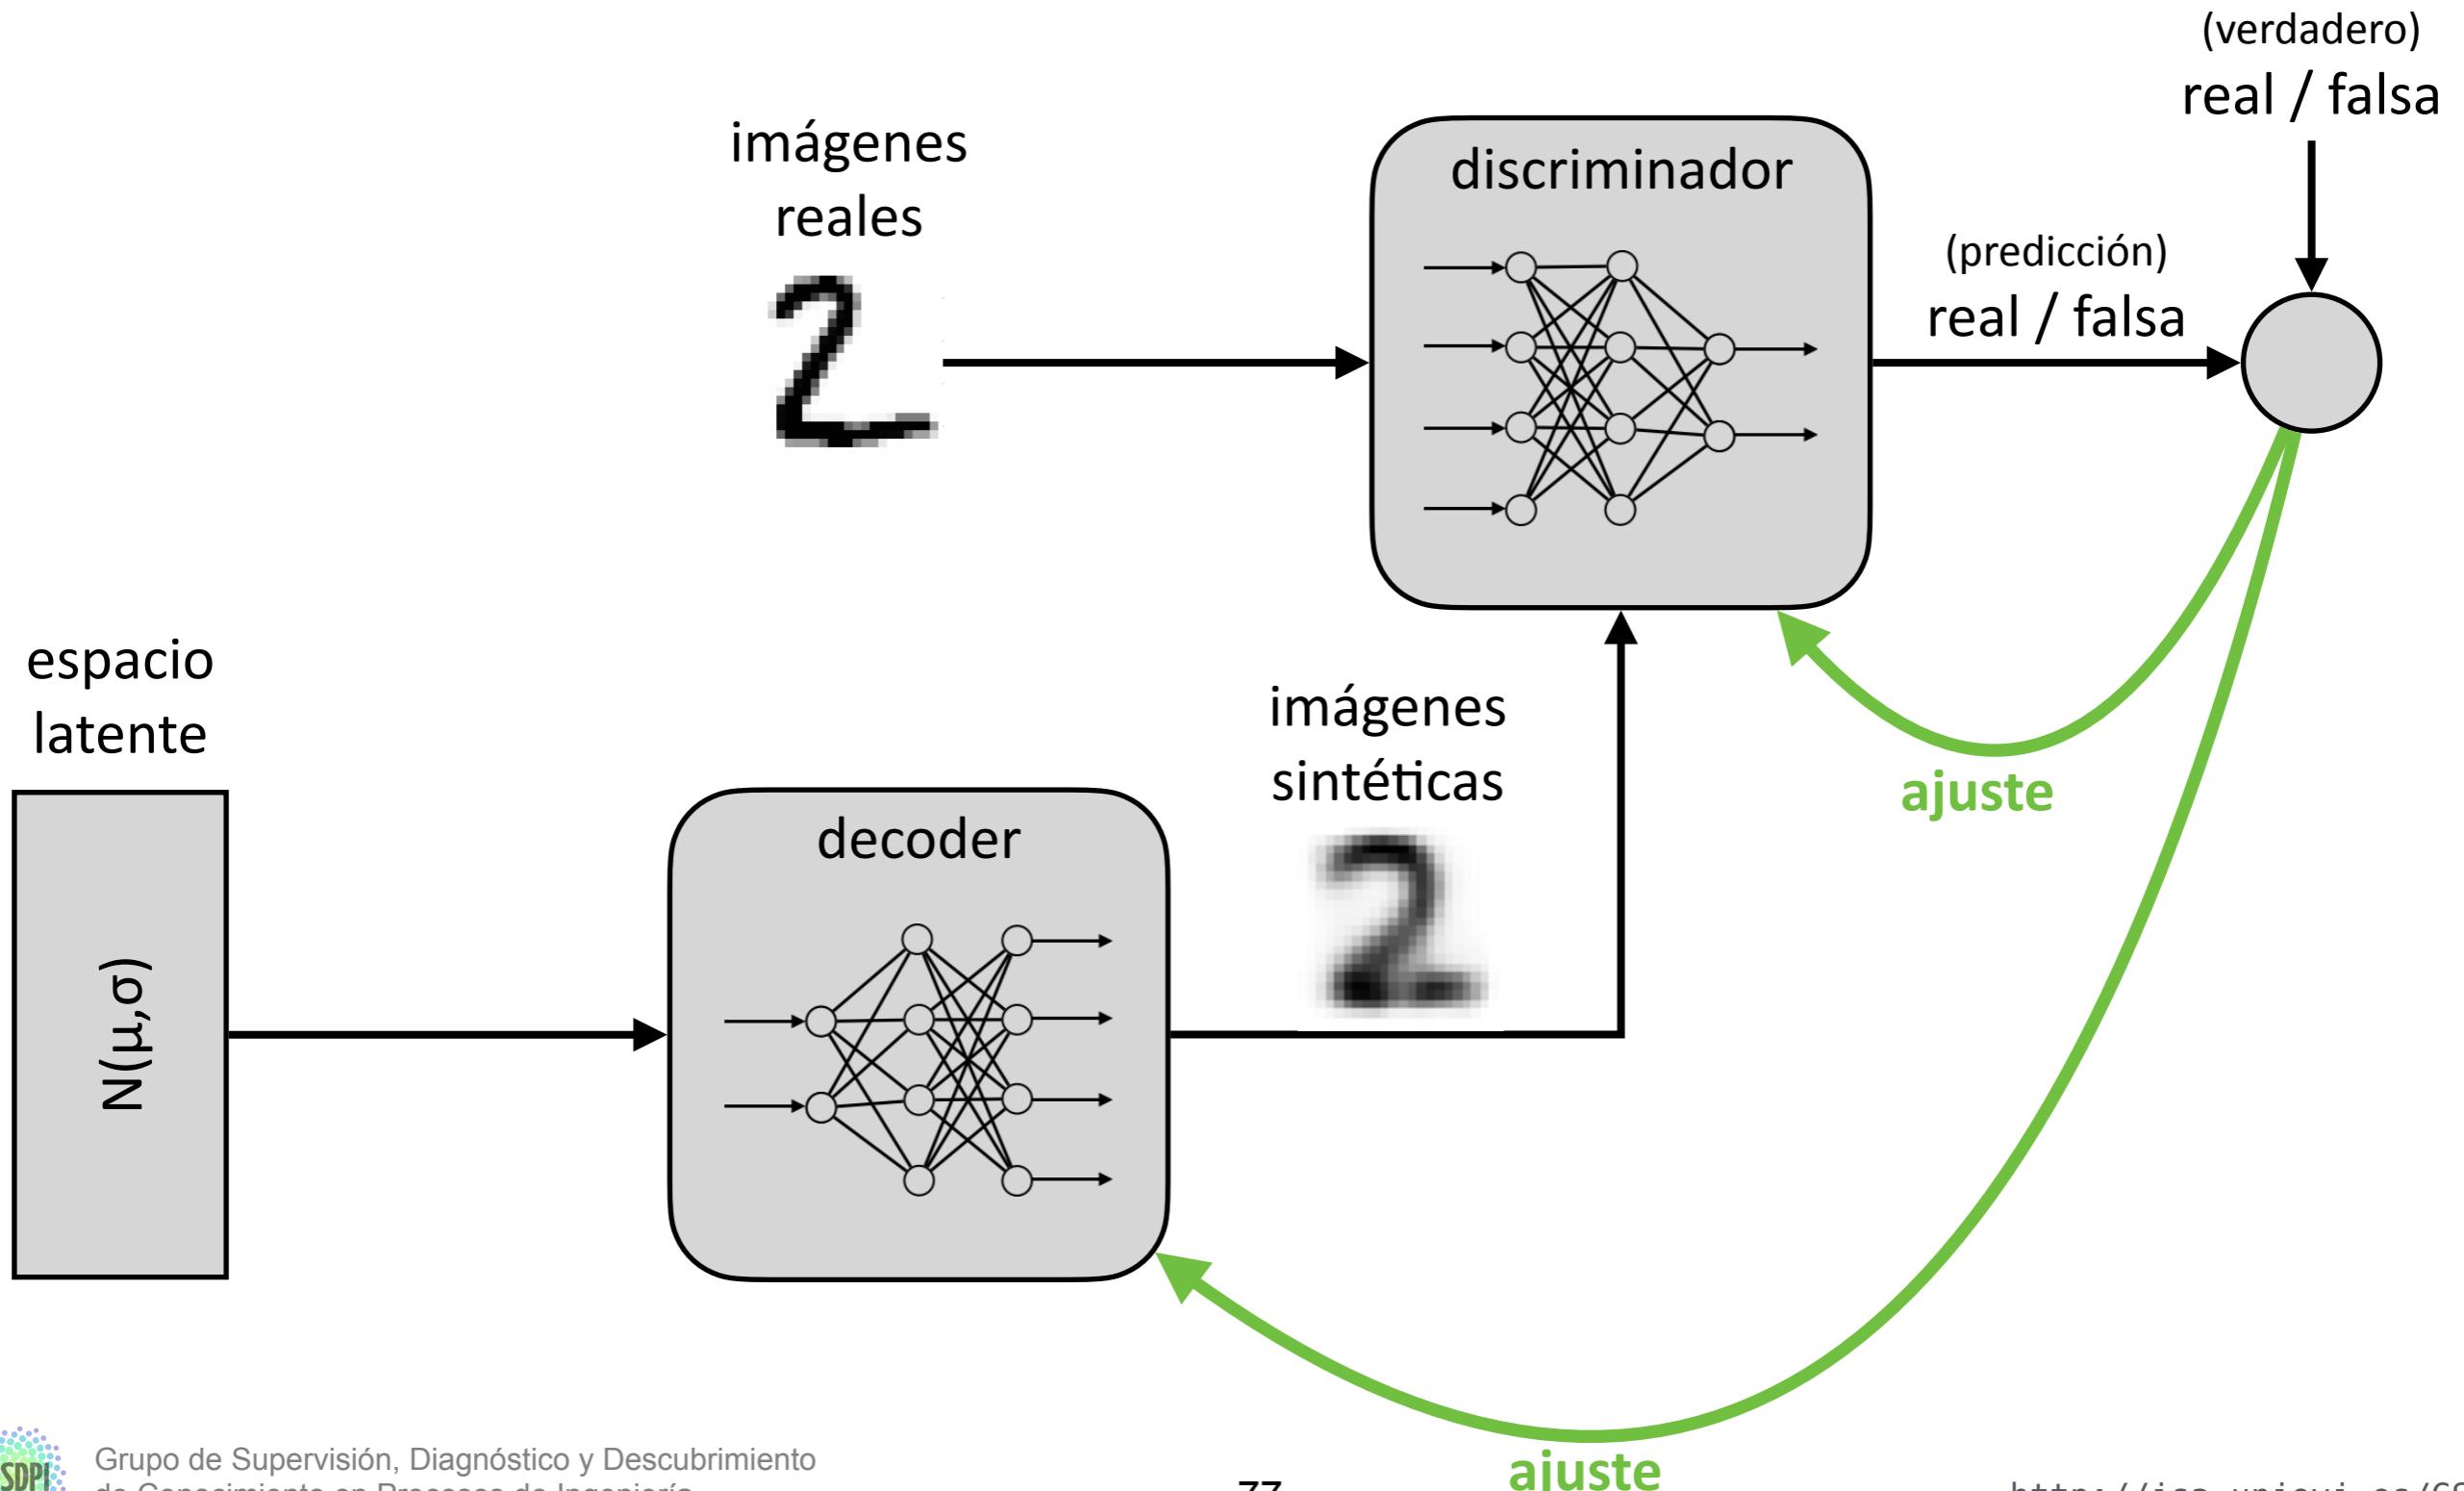
## Variational Auto-Encoder VAE

- 1) Impone restricción en espacio latente  
forzamos gaussiana  $N(0,1)$   
→ si genero un dato  $N(0,1)$  → produce imagen “creíble”
- 2) inyecta ruido durante el aprendizaje → mejor generalización



# Variantes de Autoencoders

## Generative Adversarial Network GAN



## Reconstrucción

Reconstruir imágenes o audio corruptos

## Detección de novedades

detección de fallos

detección de fraude

## Visualización de datos

generación automática de “mapas” 2D y 3D

de datos complejos (imágenes, audio, vibraciones, etc.)

## Modelos generativos

generación de ejemplos sintéticos

(imágenes, música, etc.) <https://goo.gl/s49MPU>

los ejemplos son “creíbles”: siguen las reglas de los ejemplos reales

*“How to Generate Music using a LSTM Neural Network in Keras”*

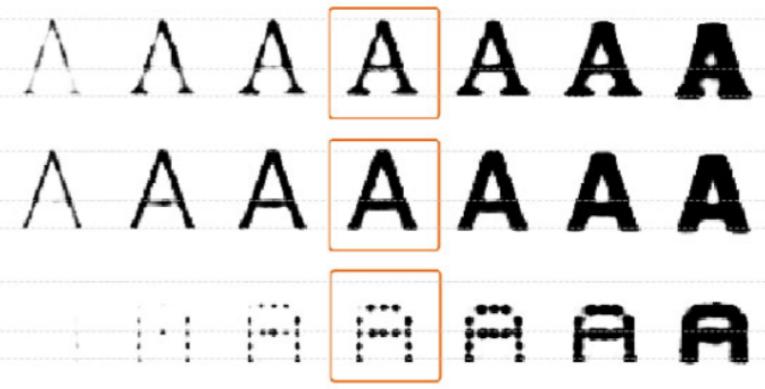
<https://distill.pub/2017/aia/>

Dec. 4, 2017

COMMENTARY

## Using Artificial Intelligence to Augment Human Intelligence

By creating user interfaces which let us work with the representations inside machine learning models, we can give people new tools for reasoning.

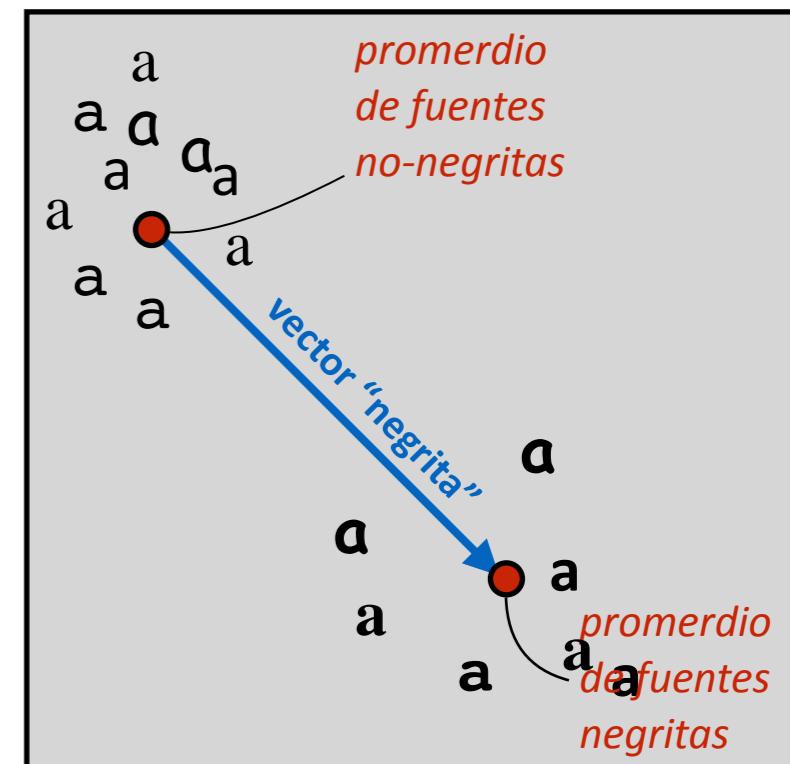


## Generación de ejemplos

fuentes, caras, frases, moléculas ...

### Idea de “vectores de atributos”

direcciones en el espacio latente  
 muestran atributos como “negrita”  
 u otras más abstractas como “sonrisa”, “femenino”, etc.



## Transfer Learning o aprendizaje inductivo

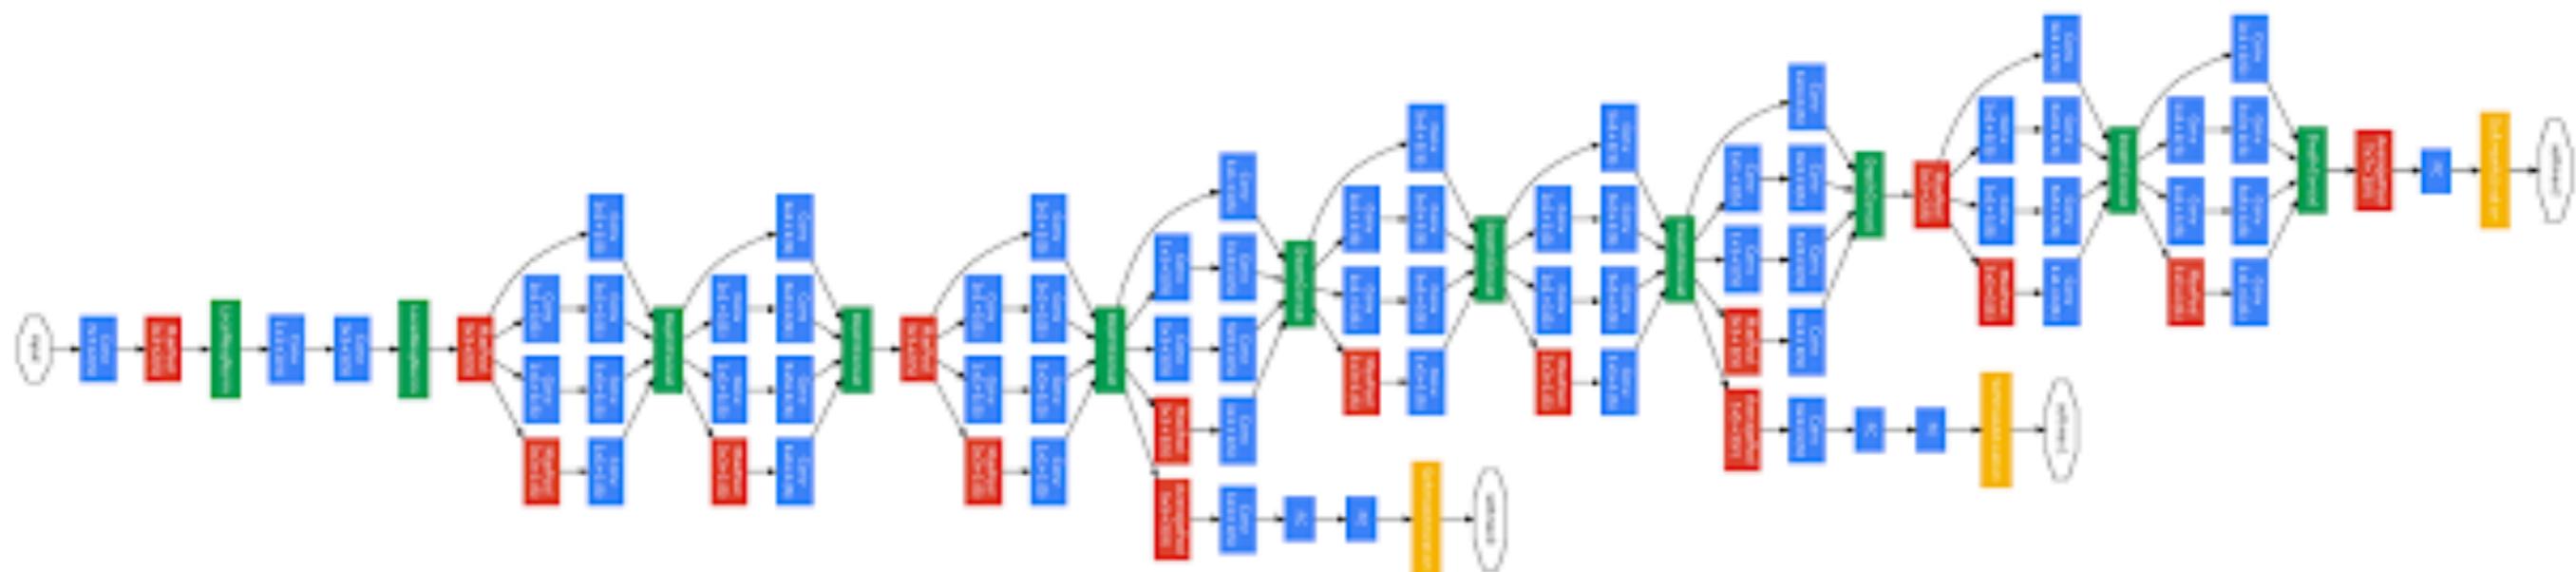
*“almacenar conocimiento obtenido resolviendo un problema y aplicarlo a otro problema diferente pero relacionado”*

Idea:

1. Entrenar una red “monstruosa”,  
**muy profunda**  
con millones de pesos,  
sobre millones de imágenes ...
  
2. Aplicarla con cambios menores  
a un problema relacionado:  
ej. → clasificar radiografías

## Existen modelos preentrenados

- Oxford VGG Model
- GoogLeNet
- Google Inception Model
- Microsoft ResNet Model
- Google's word2vec Model
- Stanford's GloVe Model
- Caffe Model Zoo

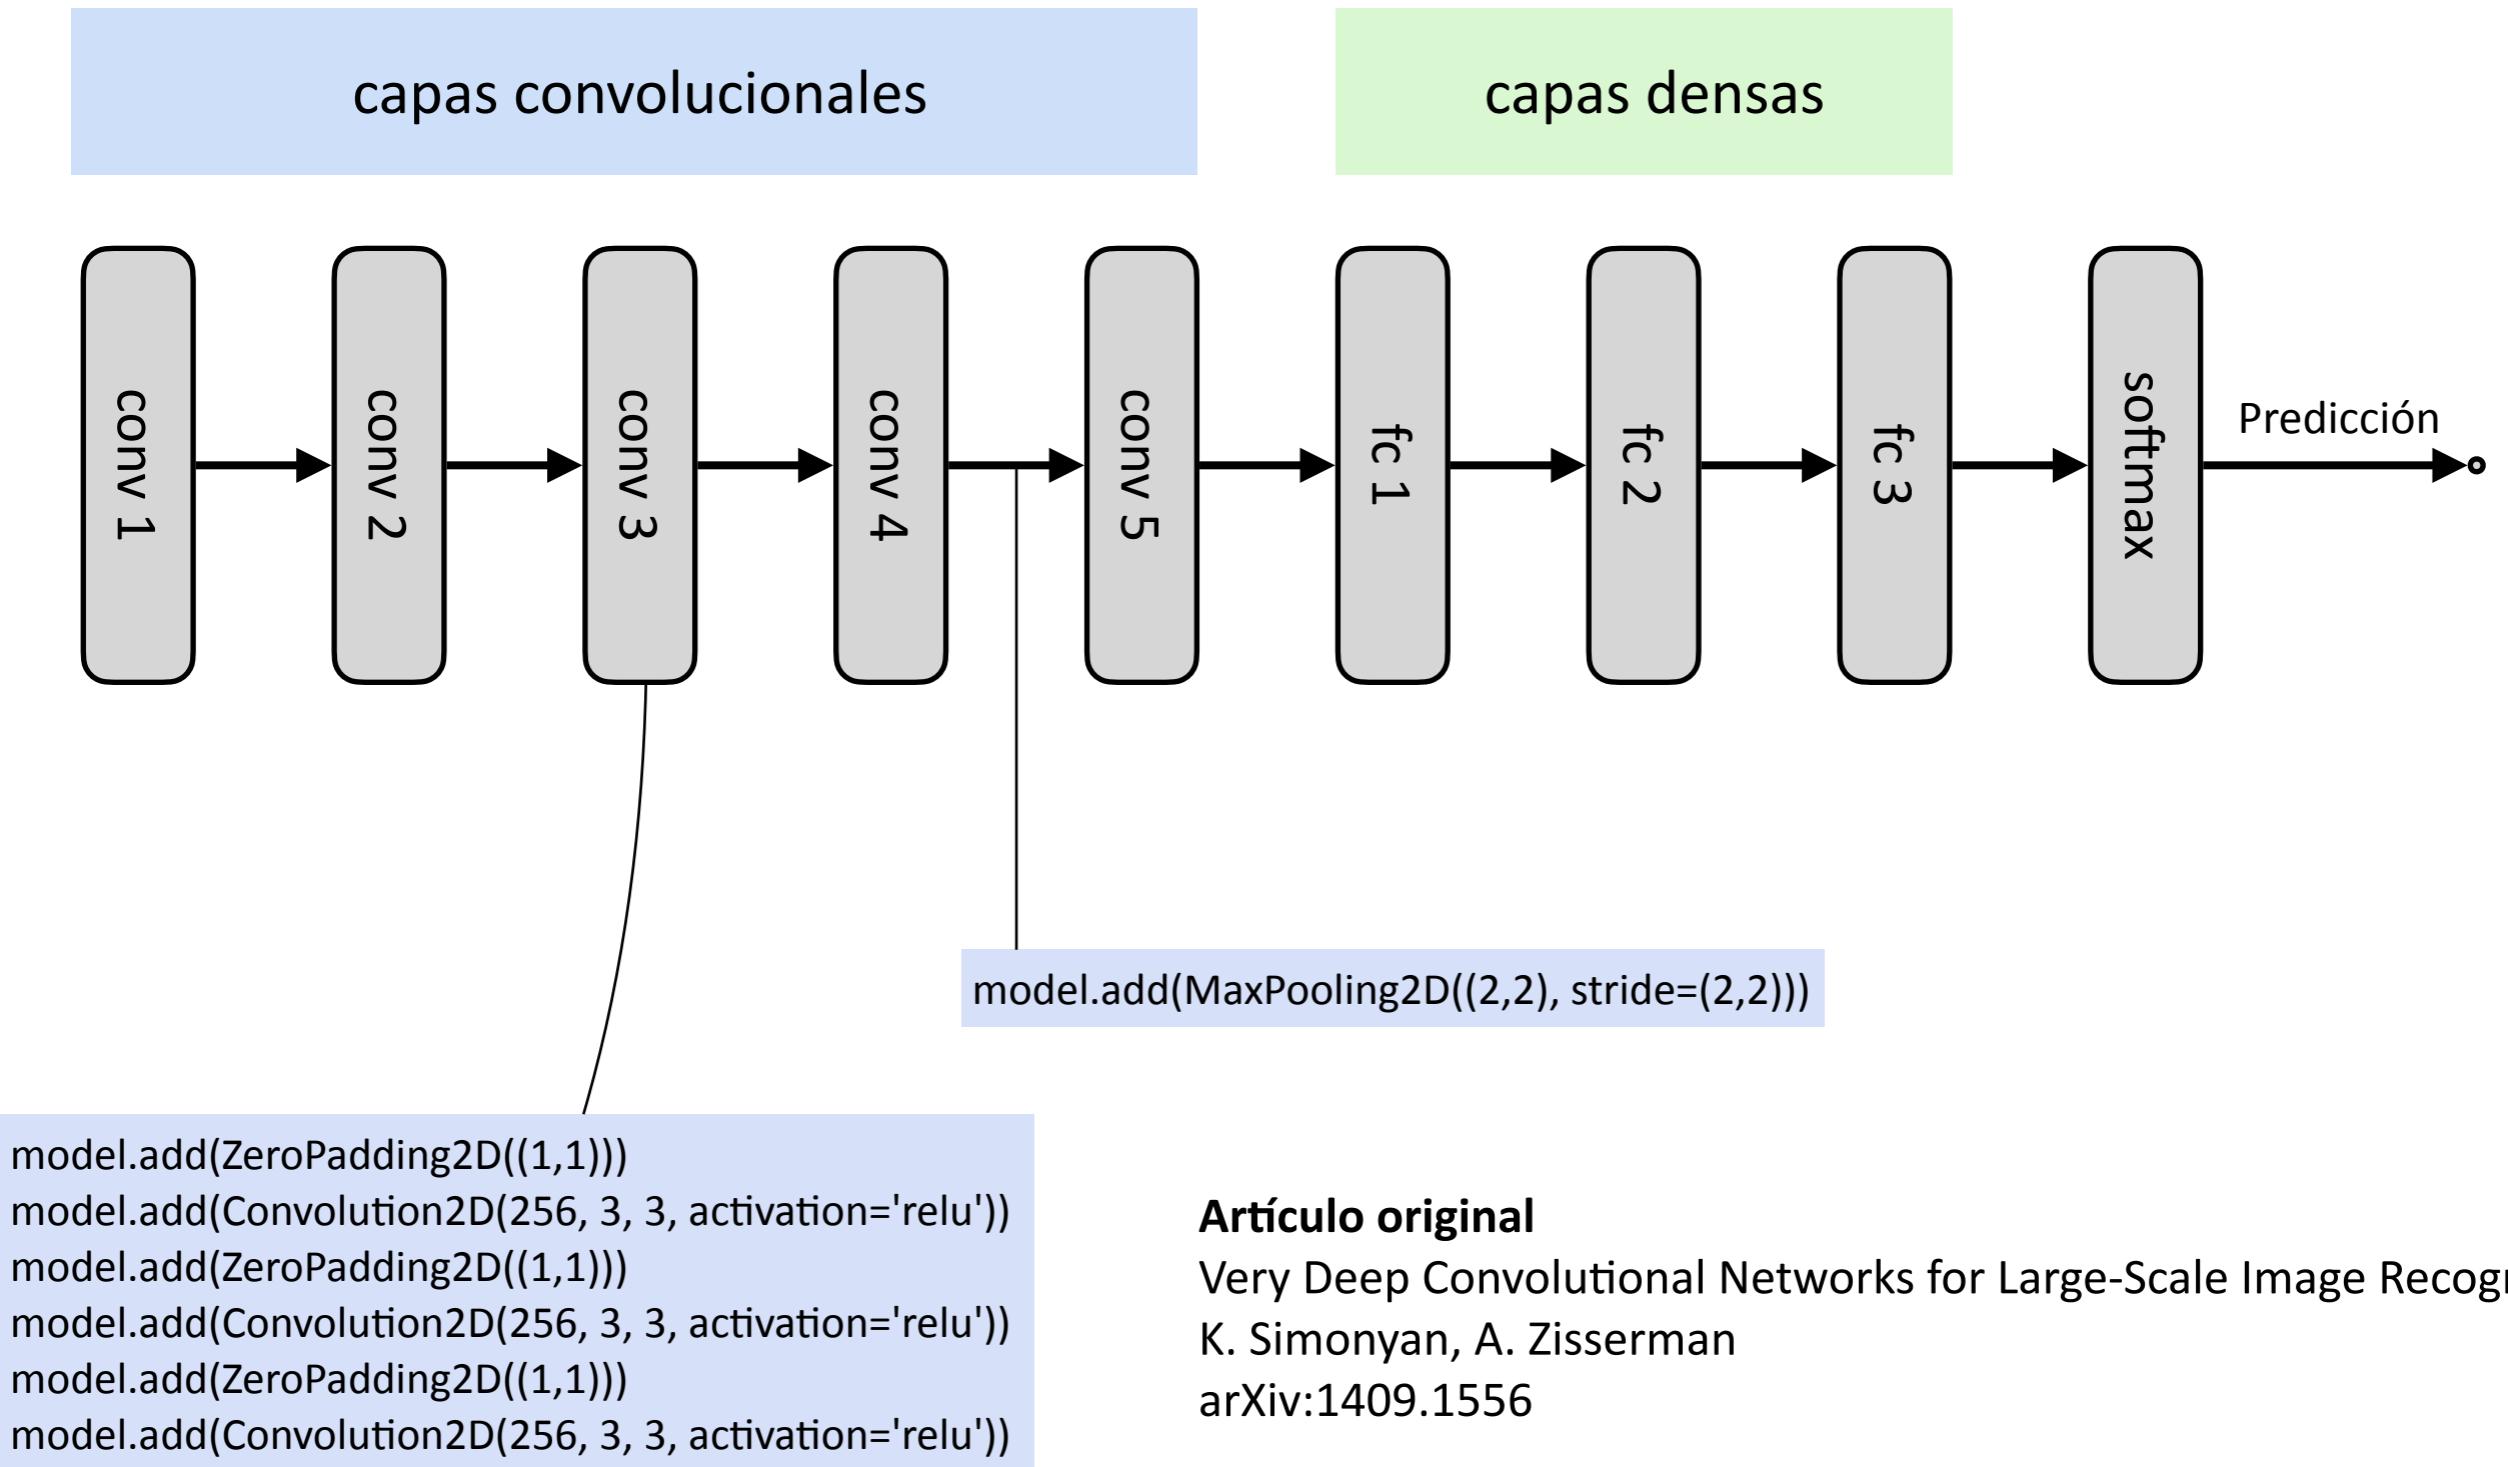


## Arquitectura GoogLeNet

fuente: "Using Machine Learning to Explore Neural Network Architecture"  
<https://goo.gl/c6vMb4>

# Transfer Learning

## Arquitectura preentrenada VGG16 en Keras



### Artículo original

Very Deep Convolutional Networks for Large-Scale Image Recognition  
 K. Simonyan, A. Zisserman  
 arXiv:1409.1556

# Algunos ejemplos y aplicaciones de deep learning

### RESEARCH

#### Generating Focussed Molecule Libraries for Drug Discovery with Recurrent Neural Networks

Marwin HS Segler<sup>1\*</sup>, Thierry Kogej<sup>2</sup>, Christian Tyrchan<sup>3</sup> and Mark P Waller<sup>4</sup>

##### Abstract

In *de novo* drug design, computational strategies are used to generate novel molecules with good affinity to the desired biological target. In this work, we show that recurrent neural networks can be trained as generative models for molecular structures, similar to statistical language models in natural language processing. We demonstrate that the properties of the generated molecules correlate very well with the properties of the molecules used to train the model. In order to enrich libraries with molecules active towards a given biological target, we propose to fine-tune the model with small sets of molecules, which are known to be active against that target.

Against *Staphylococcus aureus*, the model reproduced 14% of 6051 hold-out test molecules that medicinal chemists designed, whereas against *Plasmodium falciparum* (Malaria) it reproduced 28% of 1240 test molecules. When coupled with a scoring function, our model can perform the complete *de novo* drug design cycle to generate large sets of novel molecules for drug discovery.

**Keywords:** computer-assisted drug design; recurrent neural networks

##### 1 Introduction

Chemistry is the language of nature. Chemists speak it fluently and have made their discipline one of the true contributors to human well-being, which has “*changed the way you live and die*”.<sup>[1]</sup> This is particularly true for medicinal chemistry. However, creating novel drugs is an extraordinarily hard and complex problem.<sup>[2]</sup> One of the many challenges in drug design is the sheer size of the search space for novel molecules. It has been estimated that  $10^{60}$  drug-like molecules could possibly be synthetically accessible.<sup>[3]</sup> Chemists have to select and examine molecules from this large space to find molecules that are active towards a biological target. Active means for example that a molecule binds to a biomolecule, which causes an effect in the living organism, or inhibits replication of bacteria. Modern high-throughput screening techniques allow to test molecules in the order of  $10^6$  in the lab.<sup>[4]</sup> However, larger experiments will get prohibitively expensive. Given this practical limitation of *in vitro* experiments, it is desirable to have computational tools to narrow down the enormous search space. *Virtual screening* is a commonly used strategy to search for promising molecules amongst mil-

lions of existing or billions of virtual molecules.<sup>[5]</sup> Searching can be carried out using similarity-based metrics, which provides a quantifiable numerical indicator of closeness between molecules. In contrast, in *de-novo* drug design, one aims to directly create novel molecules that are active towards the desired biological target.<sup>[6, 7]</sup> Here, like in any molecular design task, the computer has to

- i create molecules,
- ii score and filter them, and
- iii search for better molecules, building on the knowledge gained in the previous steps.

Task i, the generation of novel molecules, is usually solved with one of two different protocols.<sup>[7]</sup> One strategy is to build molecules from predefined groups of atoms or fragments. Unfortunately, these approaches often lead to molecules that are very hard to synthesize.<sup>[8]</sup> Therefore, another established approach is to conduct virtual chemical reactions based on expert coded rules, with the hope that these reactions could then also be applied in practice to make the molecules in the laboratory.<sup>[9]</sup> These systems give reasonable drug-like molecules, and are considered as “the solution” to the structure generation problem.<sup>[2]</sup> We generally share this view. However, we have recently shown that the predicted reactions from these rule-based expert systems can sometimes fail.<sup>[10]</sup> Also, fo-

\*Correspondence: marwin.segler@uni-muenster.de

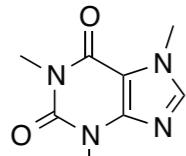
<sup>1</sup>Institute of Organic Chemistry & Center for Multiscale Theory and Computation, Westfälische Wilhelms-Universität, Münster, Germany  
Full list of author information is available at the end of the article

1. Codifica moléculas como secuencias utilizando un procedimiento estándar (*SMILES*)
2. Entrena una RNN para predecir el siguiente símbolo en una secuencia larga  
La red RNN “aprende” la gramática de moléculas válidas
3. Ajuste fino con conjunto reducido de medicamentos (analgésicos comunes)
4. A partir de una semilla la RNN genera recursivamente secuencias de medicamentos nuevas y con las propiedades de los analgésicos
5. De las secuencias se obtienen las moléculas nuevas. ¡Las propiedades físicquímicas fueron similares!

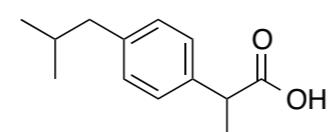
# Aplicaciones de DL

diseño de medicamentos (segler et al., 2017)

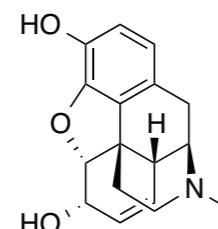
Codificación “SMILES” (molecula → secuencia)



Caffeine  
CN1C2N(C)C(=O)N(C)C1=O

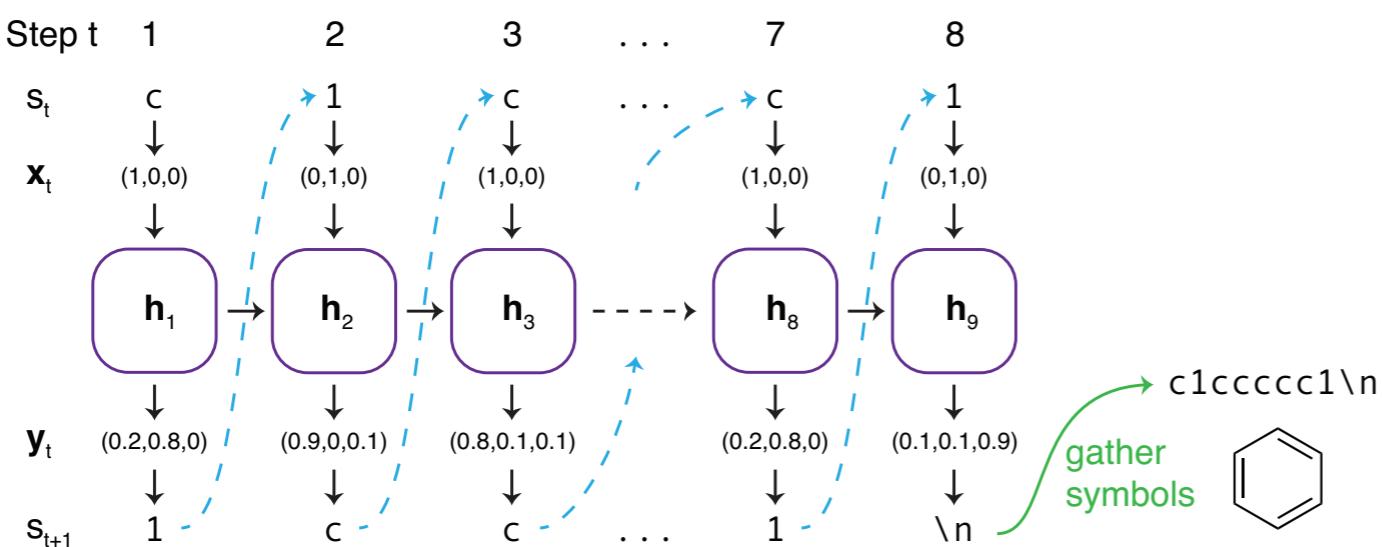


Ibuprofen  
CC(C)Cc1ccc(cc1)C(C)C(O)=O



Morphine  
[H] [C@]12C=C[C@H](O)[C@@H]30c4c5c(C[C@H]1N(C)CC[C@]235)ccc40

RNN “predecir el siguiente símbolo” de una secuencia hasta el terminador “\n”



Conjunto de datos

ChEMBL

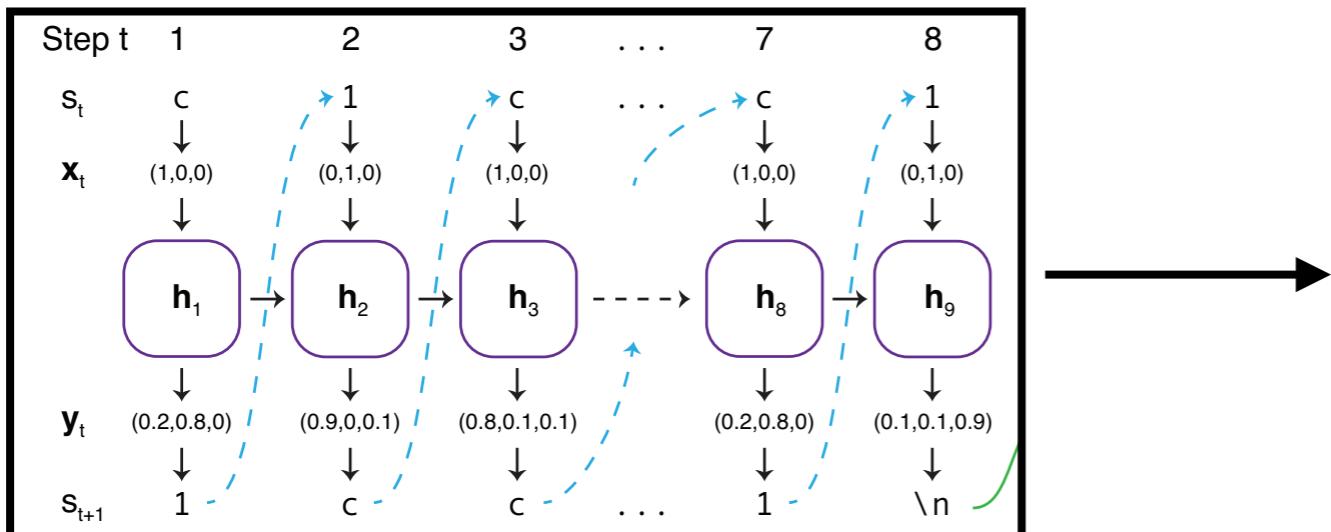
72M caracteres

vocabulario de 51 símbolos

Transfer learning

1. Entrenar para otra tarea en la que hay muchos ejemplos
2. Entrenar el conjunto más pequeño (fine tuning)

RNN genera secuencia recursivamente  
a base de predecir el siguiente símbolo

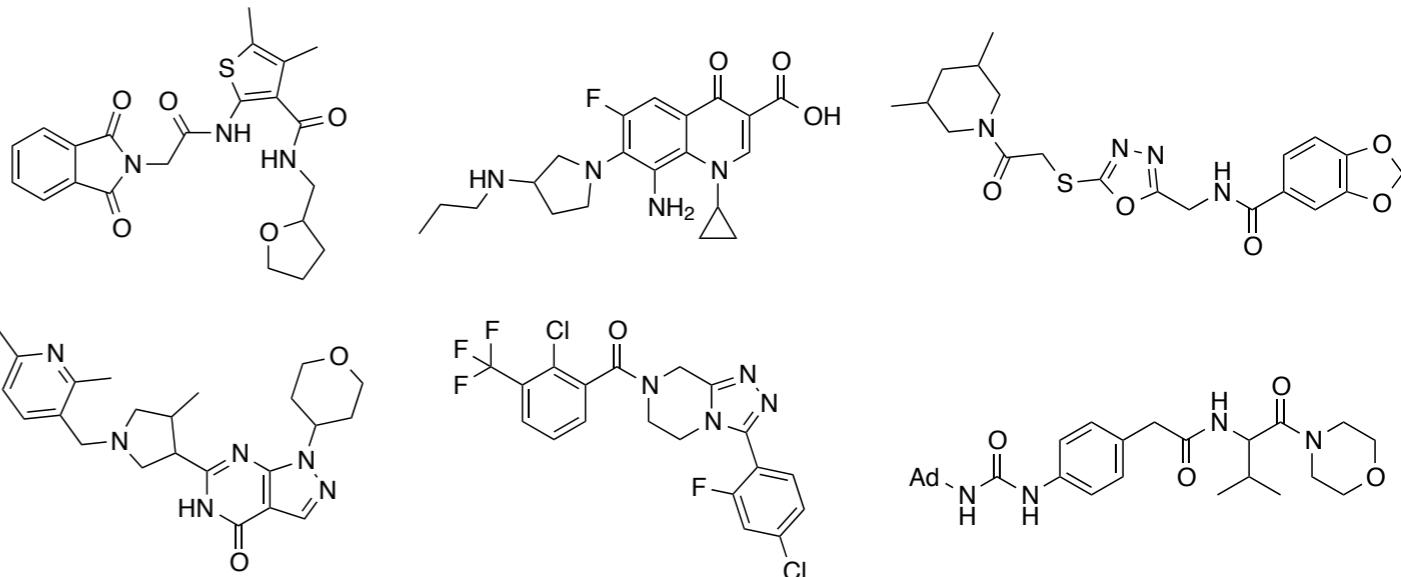


A partir del batch 3000 empieza a generar moléculas “válidas”

Batch	Generated Example	valid
0	0c.BK5i%ur+7oAFc7L3T=F8B5e=n)CS6RCTAR((0VCP1CApb)	no
1000	OF=CCC20CCCC(C2)C1CNC2CCCCCCCCCCCCCCCCCCCC	no
2000	O=C(N)C(=O)N(c1ccc10C)c2cccc20C	yes
3000	O=C1C=2N(c3cc(ccc3O2CCC1)CCC4cn(c5c(C1)cccc54)C)C	yes

↓  
Recupera moléculas  
a partir de  
las secuencias *SMILE*

Las moléculas resultantes  
fueron similares a las de  
entrenamiento en 7  
descriptores físico-  
químicos



# Aplicaciones de DL

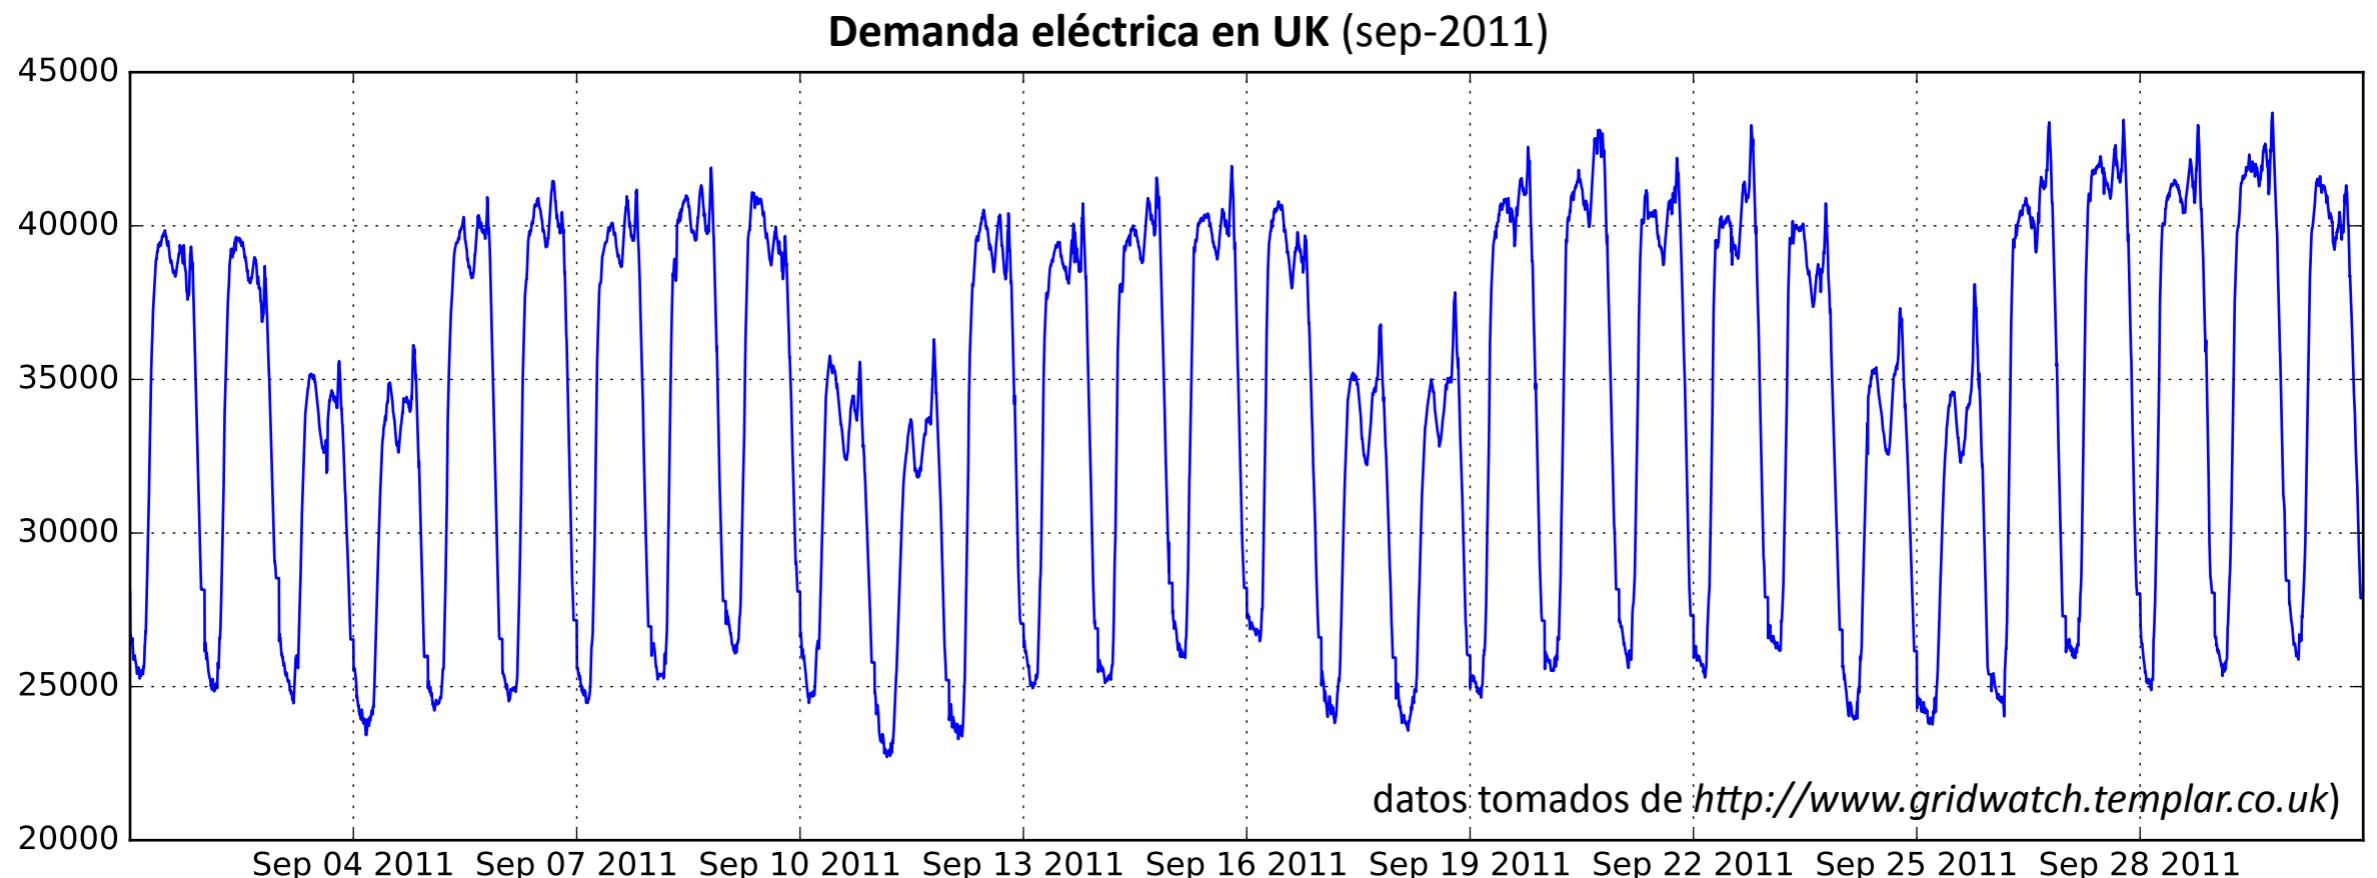
## Predicción de demanda eléctrica

### Objetivo

predecir la demanda eléctrica  
en las 24 h siguientes

**... a partir de**

demandas de las últimas 48 horas ( $N=48$ )  
semana del año ( $W$ )  
día de la semana ( $D$ )  
hora del día ( $H$ )



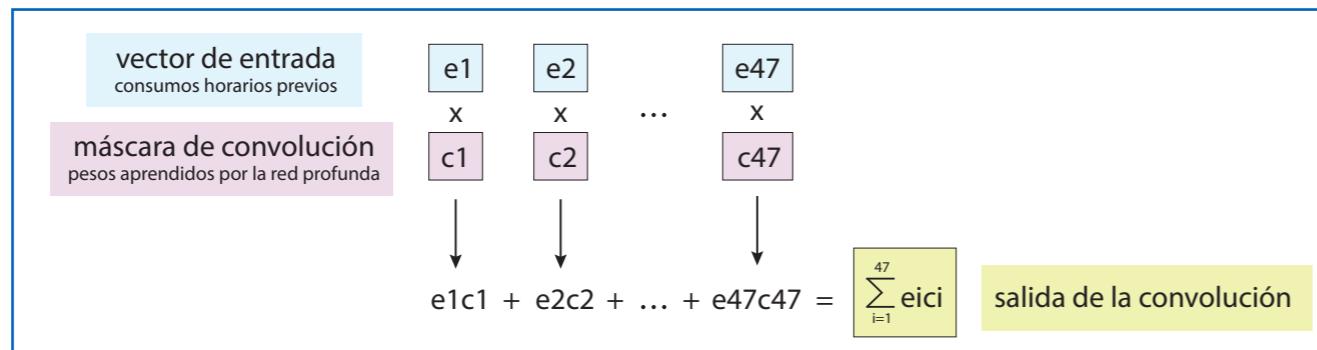
### Fuente

Ana González Muñiz, "Aplicaciones de técnicas de inteligencia artificial basadas en aprendizaje profundo (deep learning) al análisis y mejora de la eficiencia de procesos industriales". Trabajo Fin de Máster Universidad de Oviedo. Director, Ignacio Díaz Blanco.

# Aplicaciones de DL

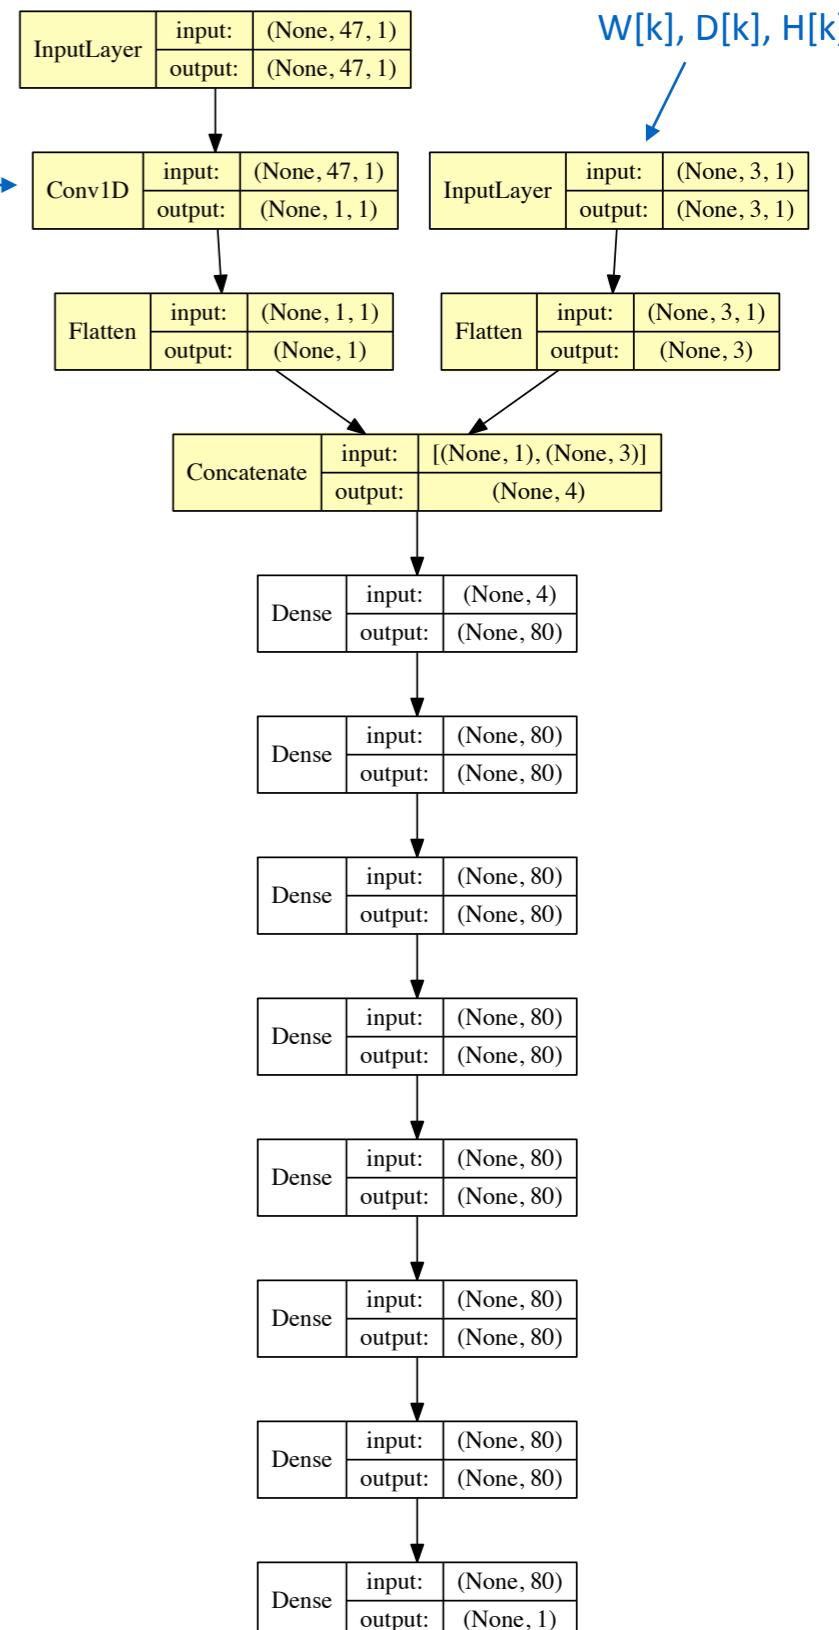
## Predicción de demanda eléctrica

Convolución con ventana de 48h de consumos previos

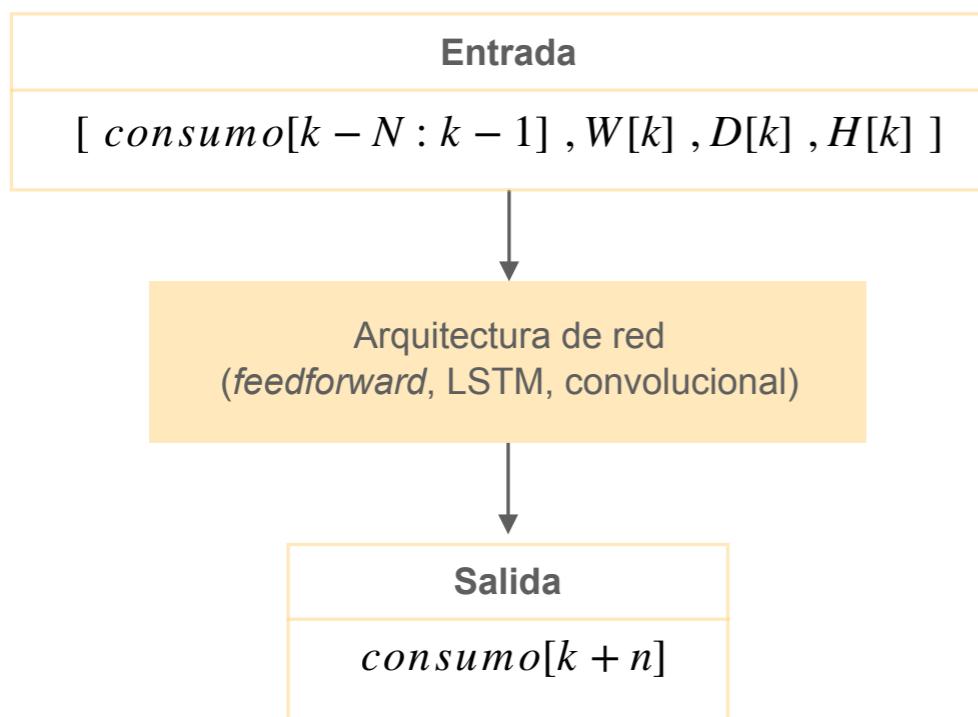


### Arquitectura convolucional

contexto  
 $W[k], D[k], H[k]$



## Planteamiento



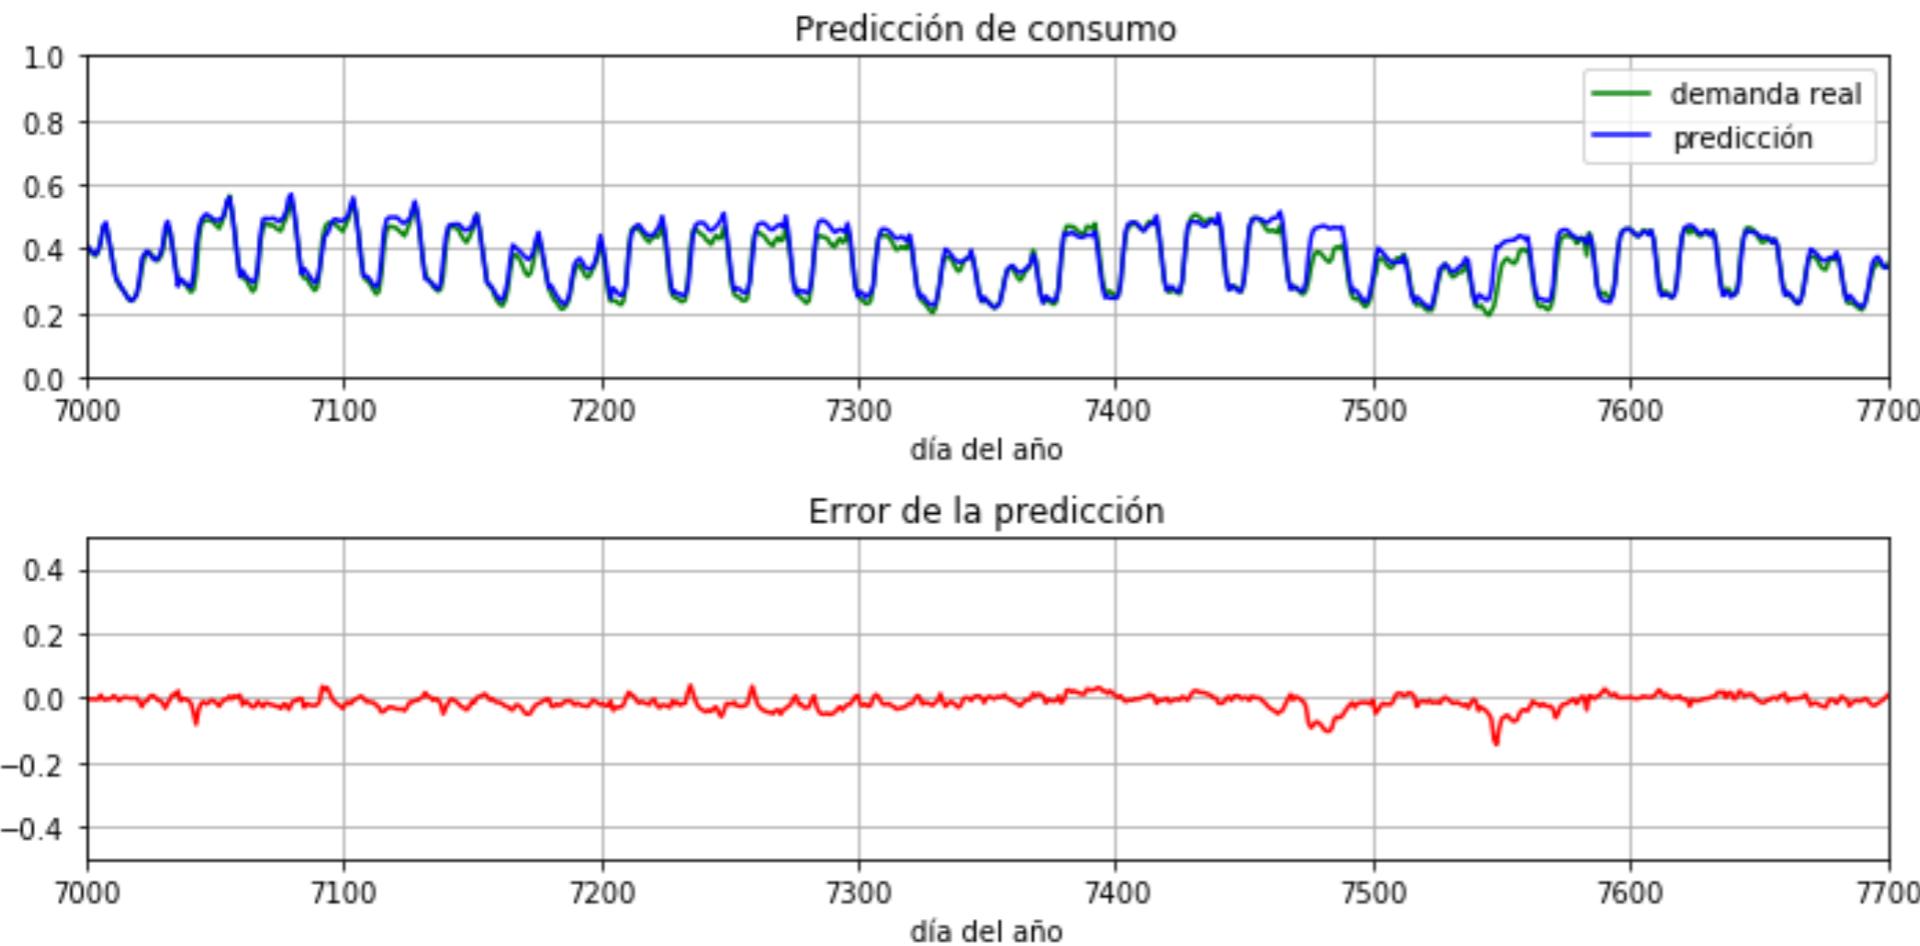
### Fuente

Ana González Muñiz, "Aplicaciones de técnicas de inteligencia artificial basadas en aprendizaje profundo (deep learning) al análisis y mejora de la eficiencia de procesos industriales". Trabajo Fin de Máster Universidad de Oviedo. Director, Ignacio Díaz Blanco. GSDPI. Departamento de Didáctica y Recursos de Aprendizaje. Facultad de Ciencias de la Ingeniería y la Arquitectura. Universidad de Oviedo. 2016.

# Aplicaciones de DL

## Predicción de demanda eléctrica

### Resultados



### Comparación con otros métodos

	Error cuadrático medio	
	Entrenamiento	Test
Red <i>feedforward</i>	$6.88 \times 10^{-4}$	$9.04 \times 10^{-4}$
Red LSTM	$5.55 \times 10^{-4}$	$5.99 \times 10^{-4}$
Red convolucional	$5.90 \times 10^{-4}$	$6.00 \times 10^{-4}$
Modelo lineal (Ridge Regression)	$29.83 \times 10^{-4}$	$31.51 \times 10^{-4}$
SVR (Kernel rbf)	$5.71 \times 10^{-4}$	$7.58 \times 10^{-4}$

### Fuente

Ana González Muñiz, "Aplicaciones de técnicas de inteligencia artificial basadas en aprendizaje profundo (deep learning) al análisis y mejora de la eficiencia de procesos industriales". Trabajo Fin de Máster Universidad de Oviedo. Director, Ignacio Díaz Blanco.

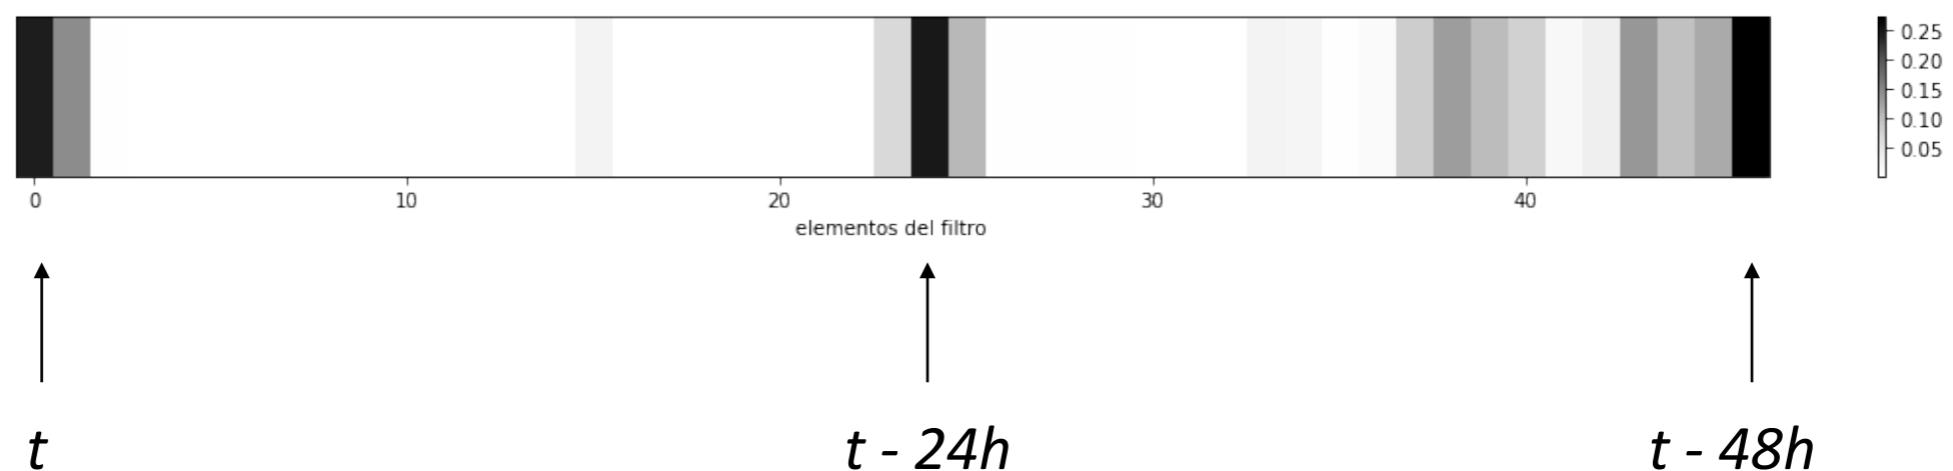
# Aplicaciones de DL

## Predicción de demanda eléctrica

### Resultados

## Aprendizaje de la representación

Pesos de las 48h anteriores  
asignados por la capa convolucional



la red fue, además, capaz de determinar por sí misma  
qué horas son relevantes en la predicción  
del consumo 24h después

#### Fuente

Ana González Muñiz, "Aplicaciones de técnicas de inteligencia artificial basadas en aprendizaje profundo (deep learning) al análisis y mejora de la eficiencia de procesos industriales". Trabajo Fin de Máster Universidad de Oviedo. Director, Ignacio Díaz Blanco.  
 GSDPI de Conocimiento en Procesos de Ingeniería

**Ficha Técnica**

**Archivo**

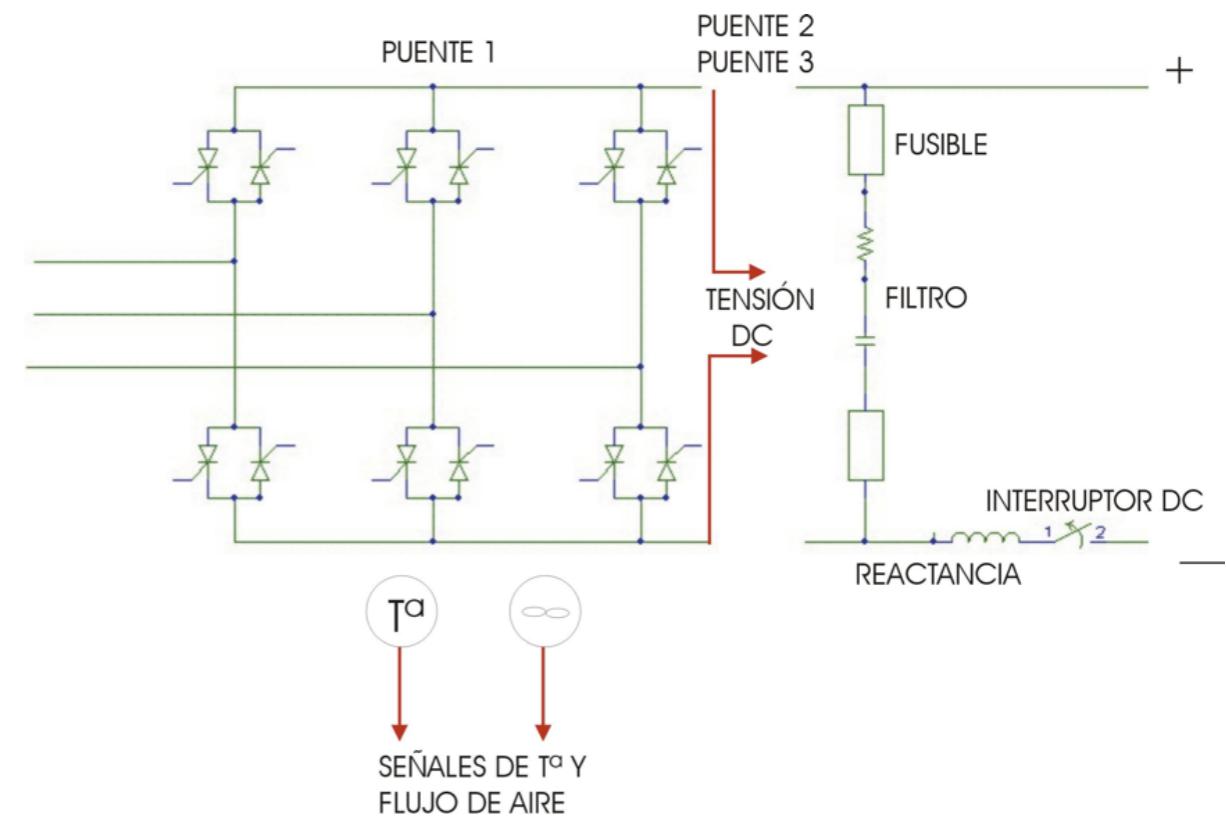
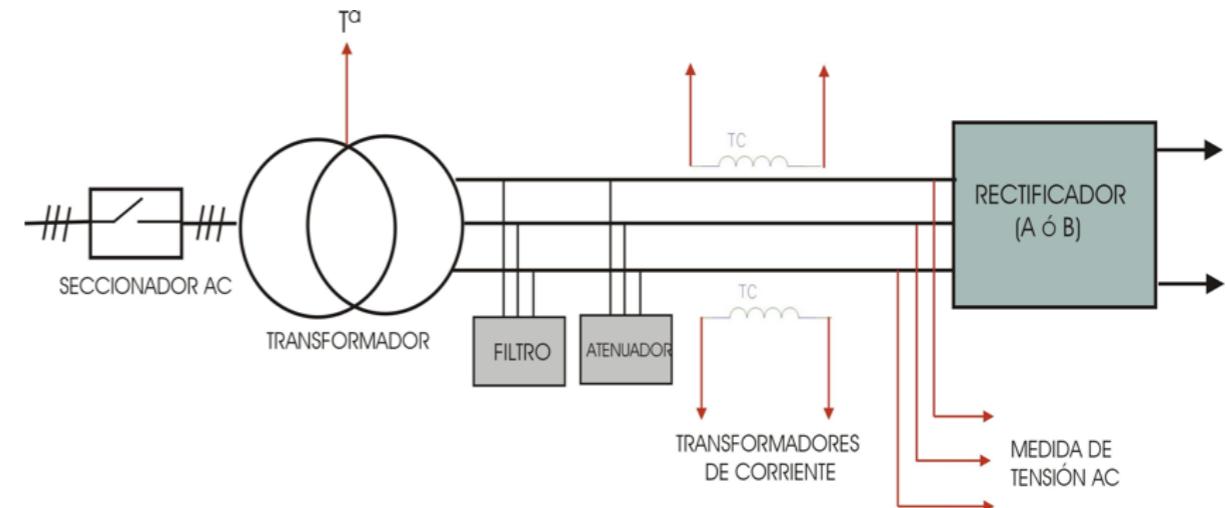
- [datosmotorlaminacion.zip](#)

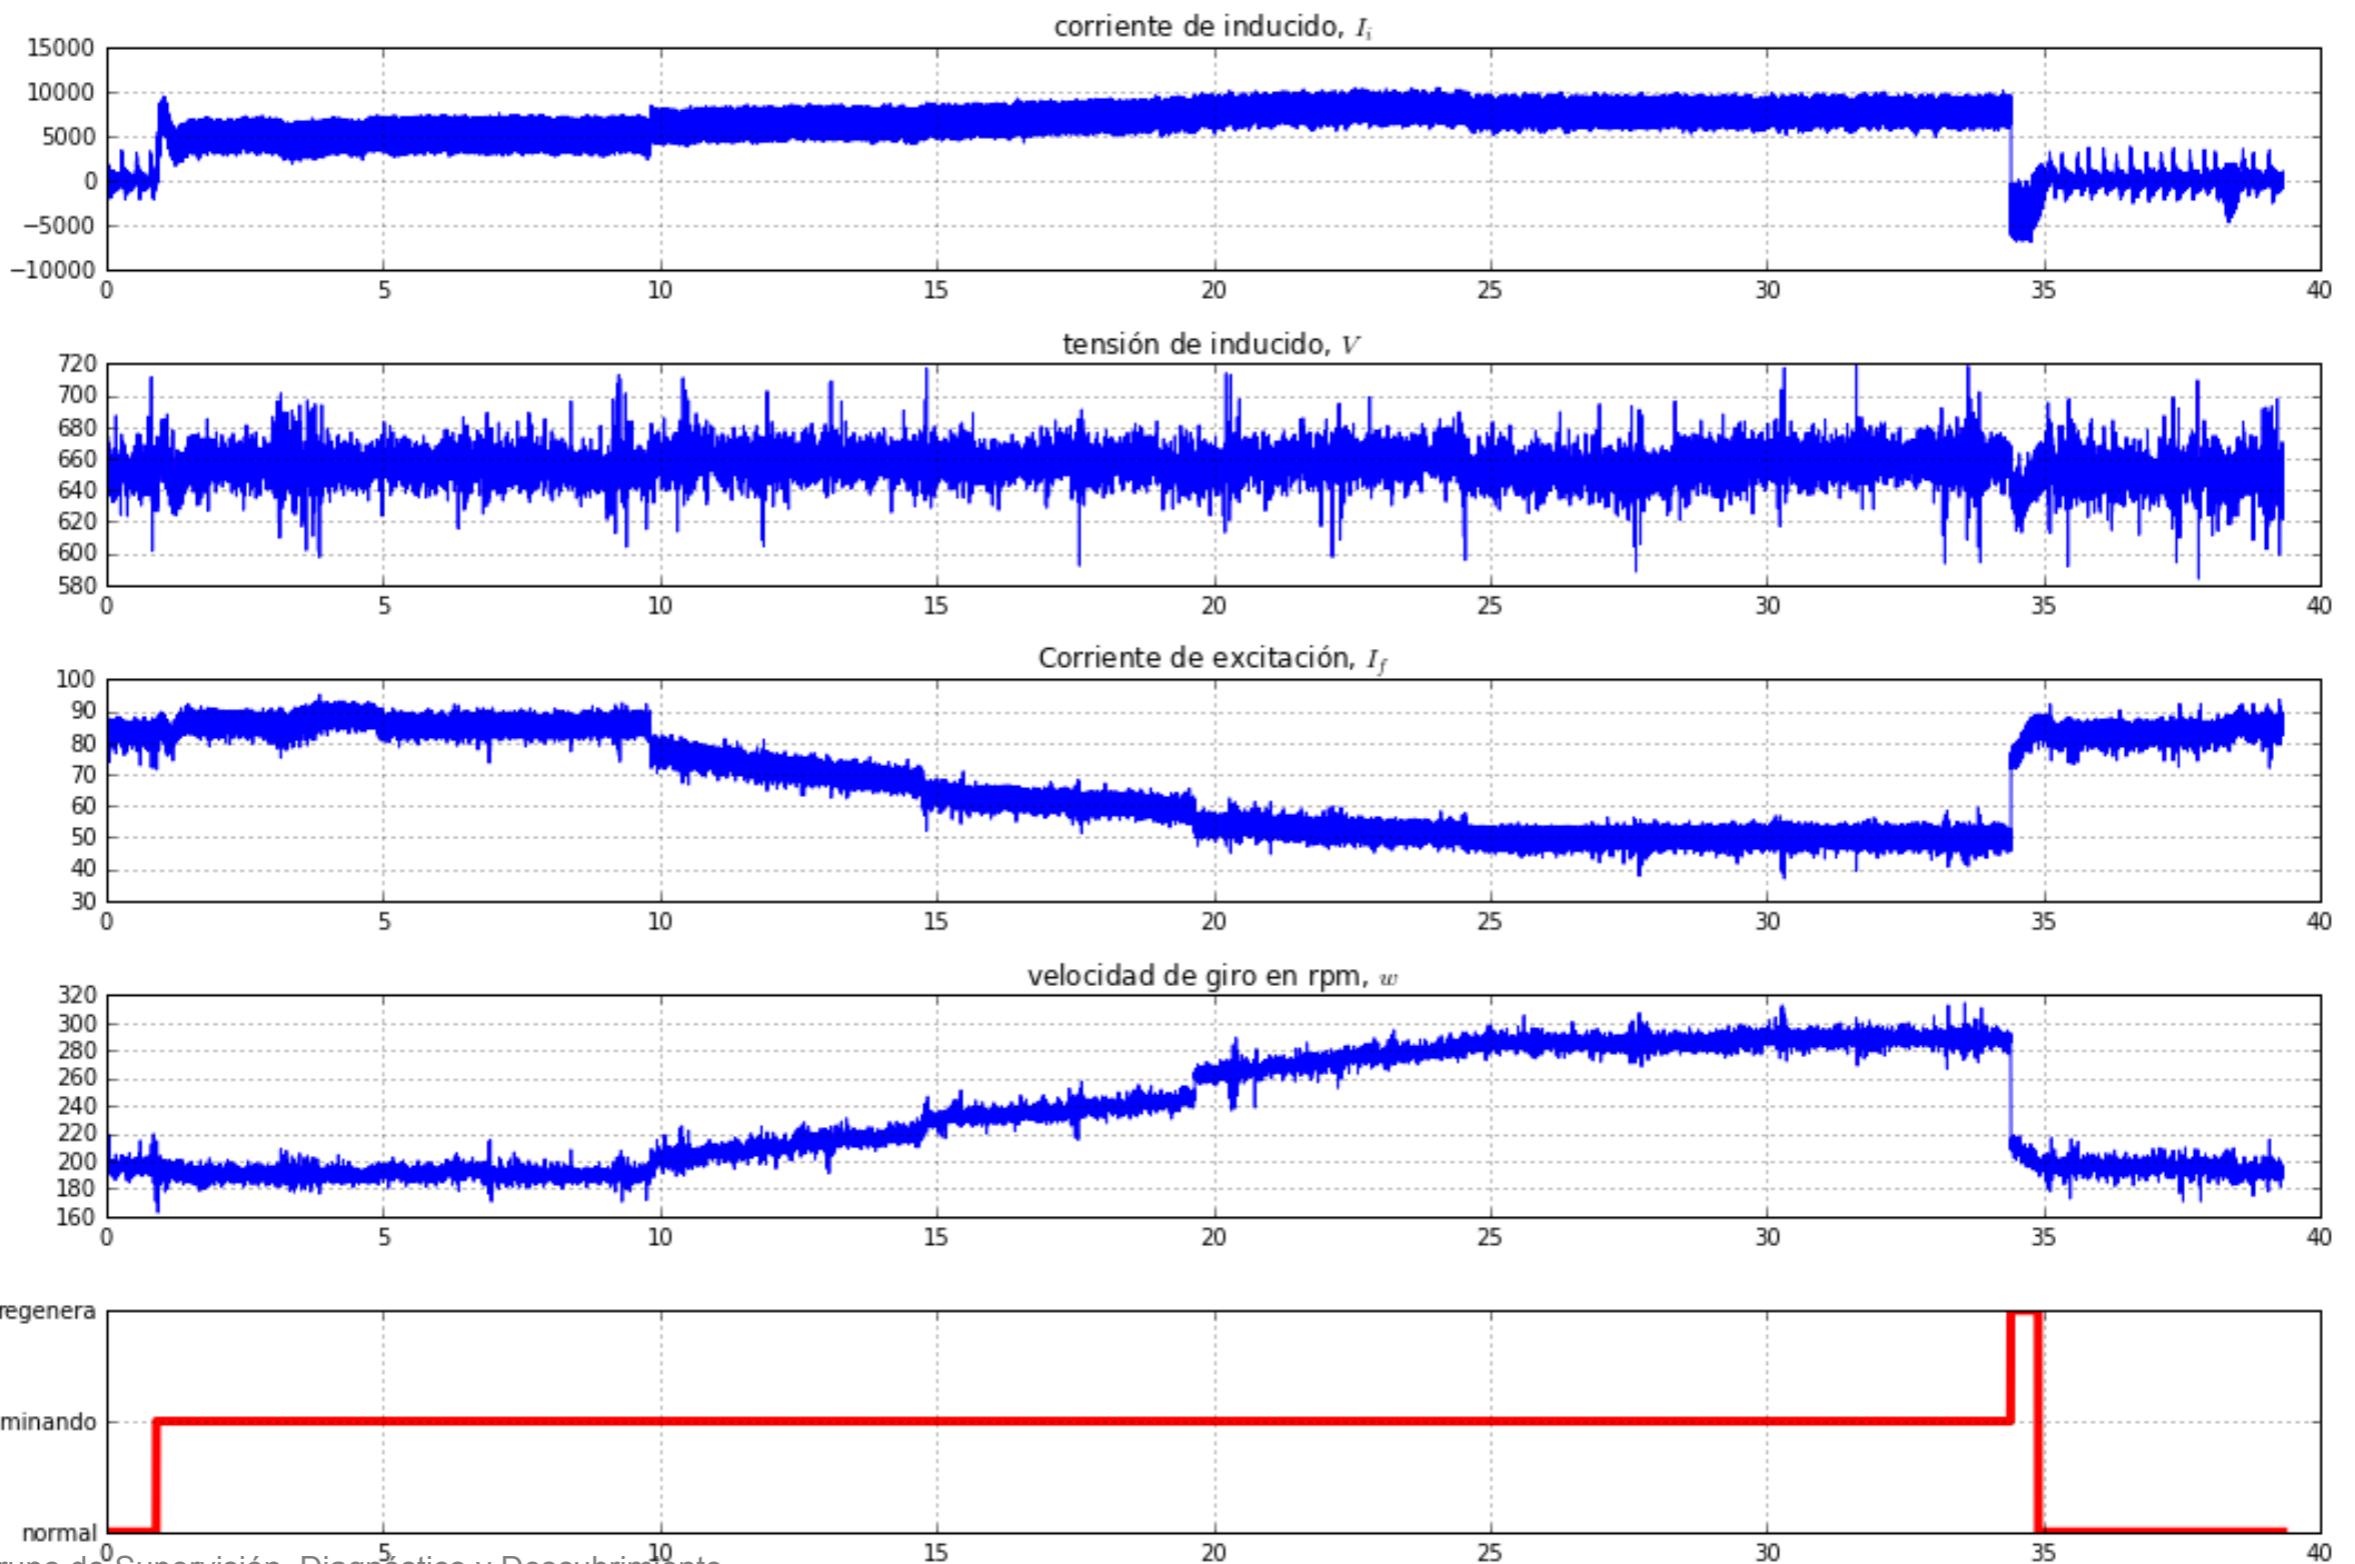
**Descripción**

Variables del motor antes, durante y después de una laminación en el TBC. El motor en cuestión ya no existe y ha sido reemplazado en una remodelación del TBC.

**Características del motor**

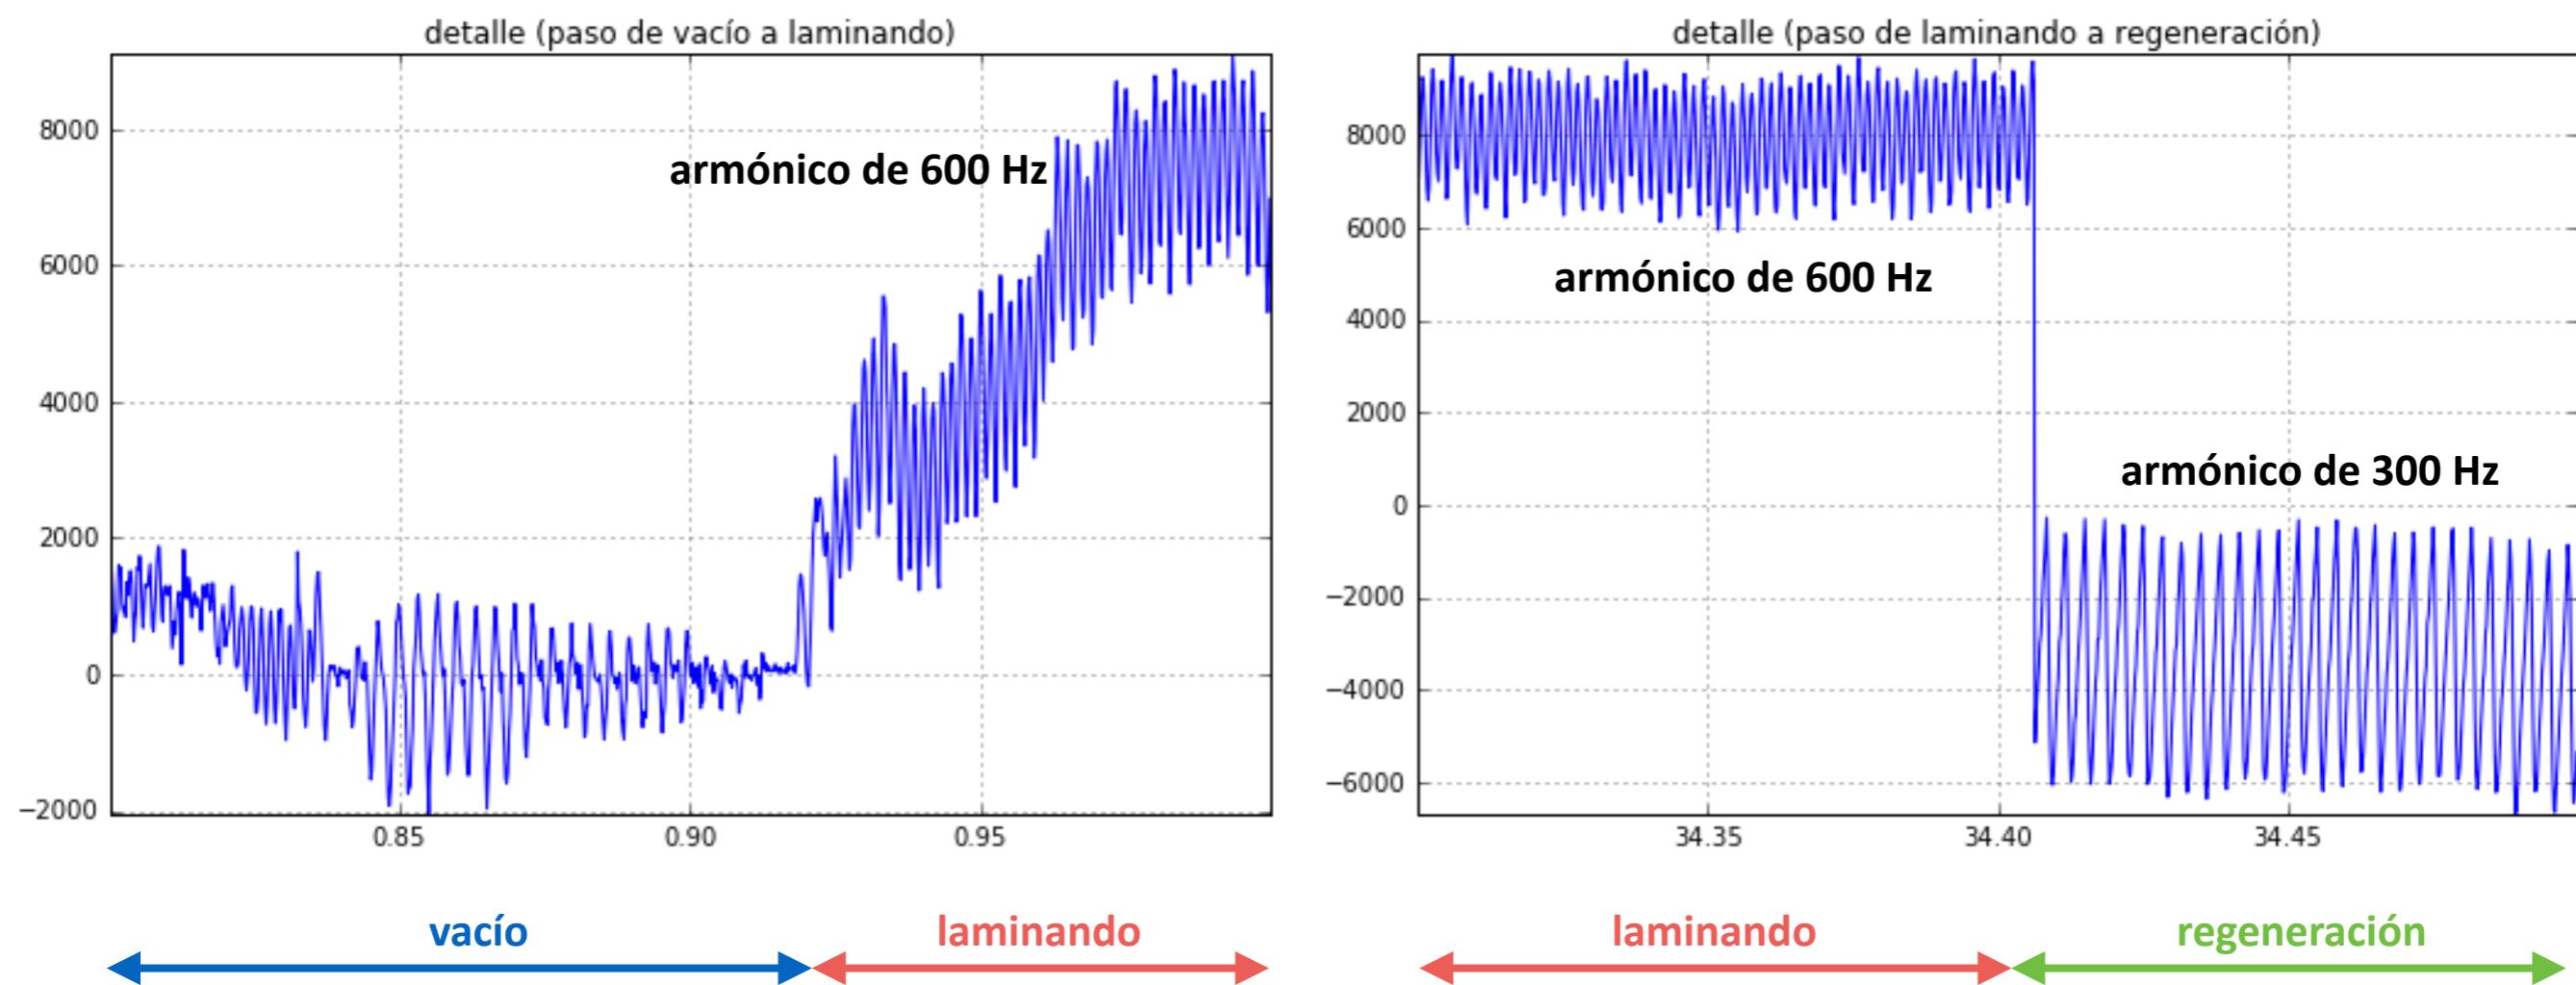
- Motor CC de excitación independiente
- Potencia: 6000 kW
- Tensión de inducido nominal: 700 V
- Corriente de inducido nominal: 9000 A
- Corriente de campo nominal: 150 A
- Velocidad nominal: 180 rpm
- Velocidad máxima: 360 rpm
- Localización: Tren acabador en caliente
- Caja: F2





# Aplicaciones de DL

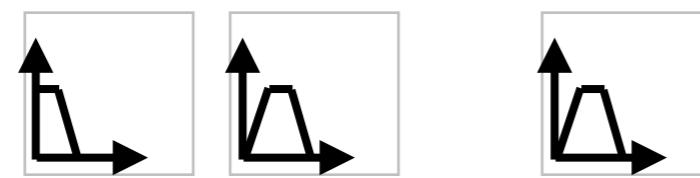
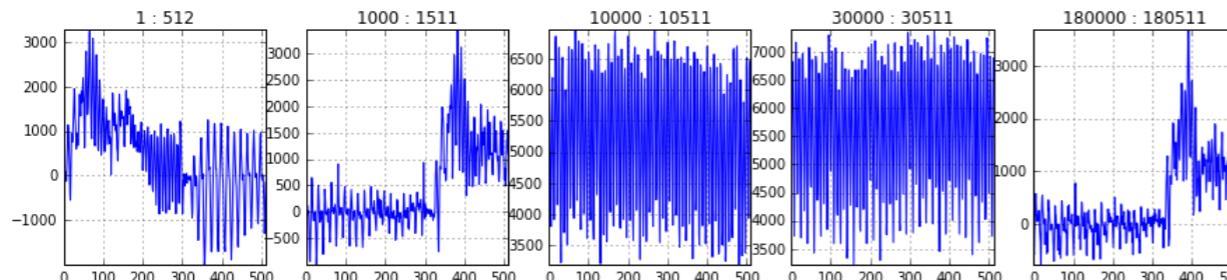
## Análisis de corrientes en motor DC



# Aplicaciones de DL

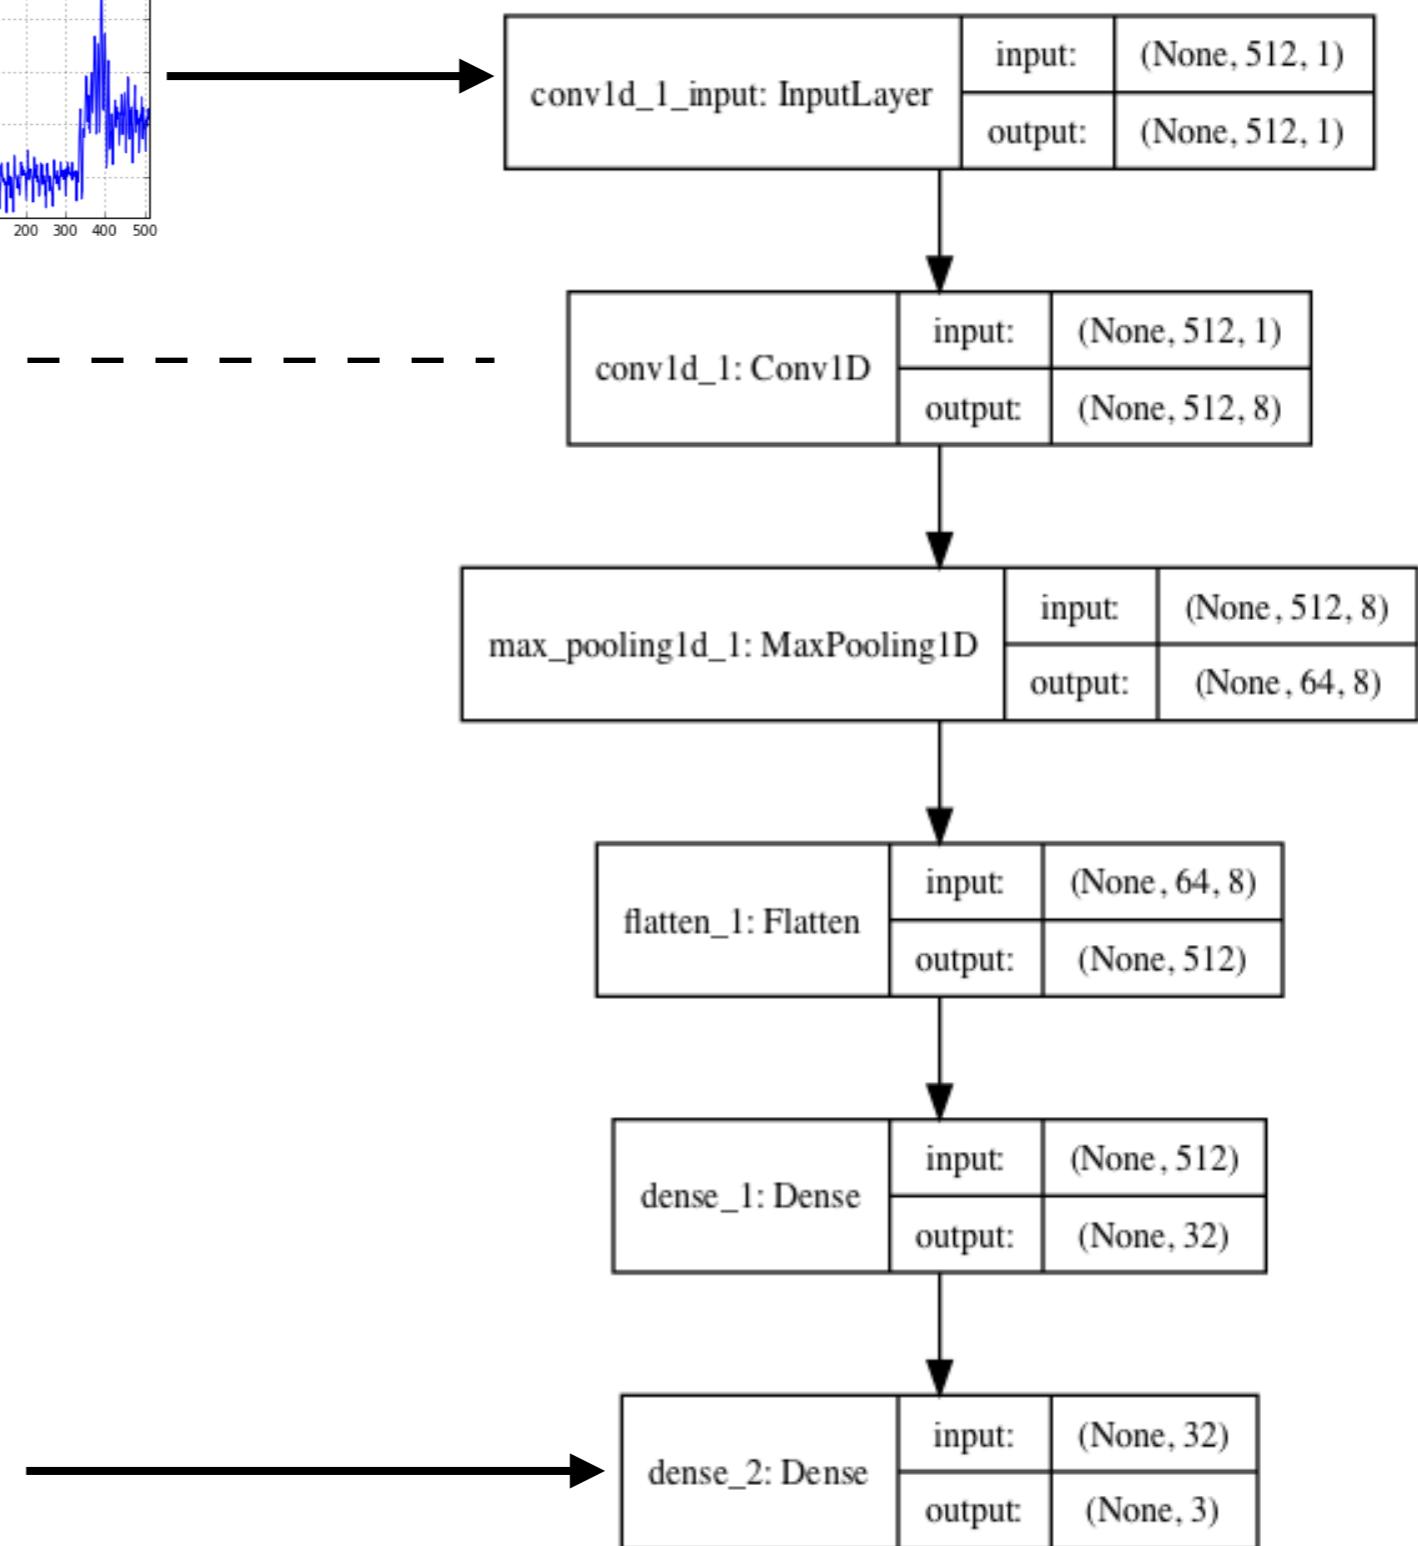
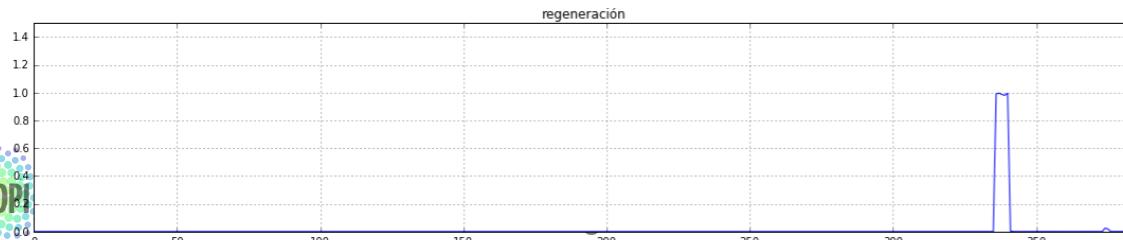
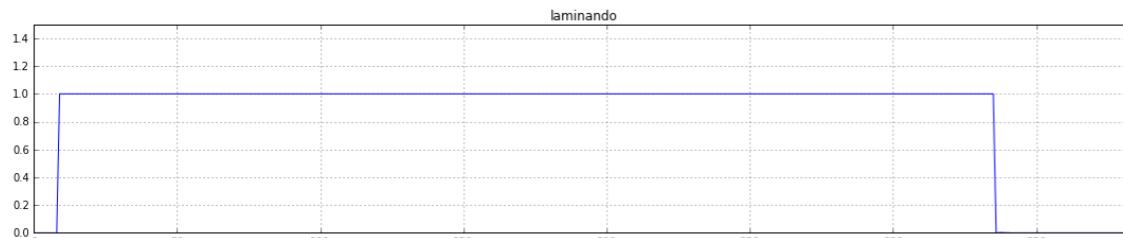
## Análisis de corrientes en motor DC

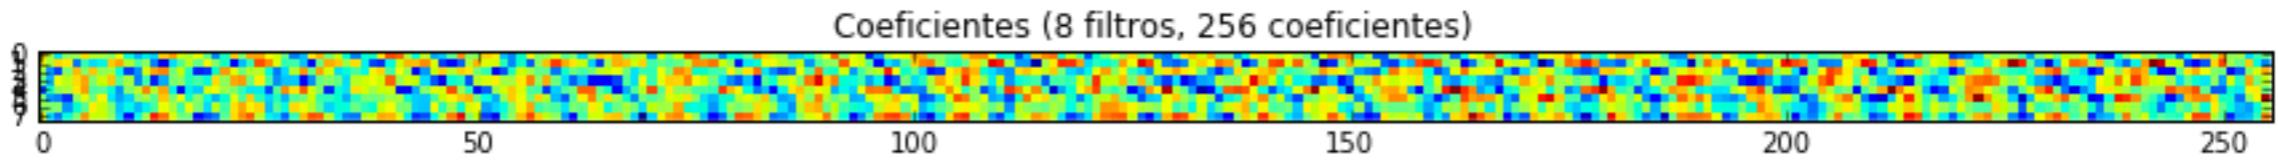
Ventanas de datos de entrada



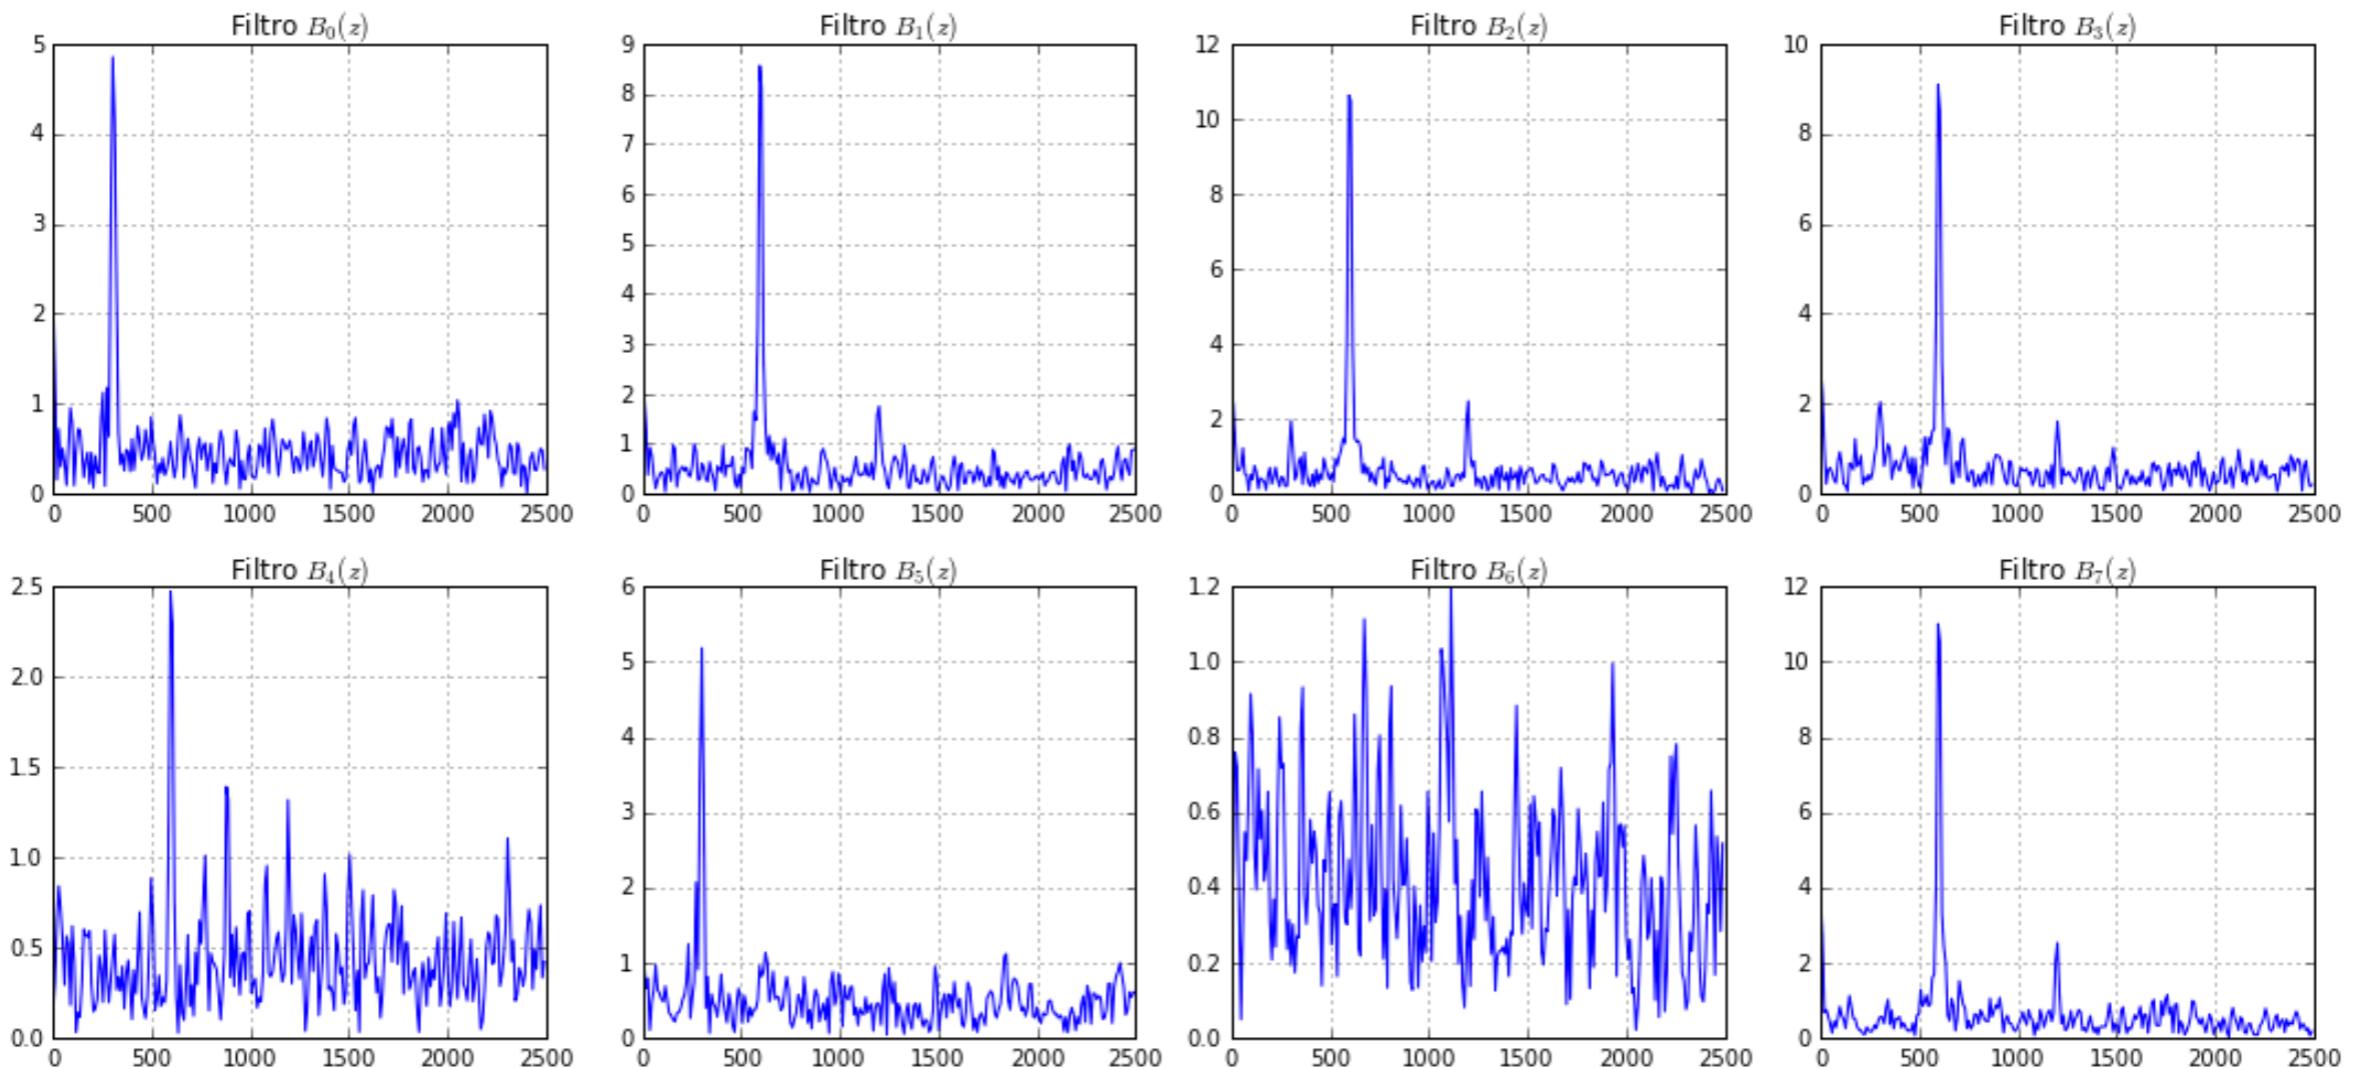
Banco de 8 filtros de 256 coeficientes

Clases (“one-hot” encoding)





### Respuestas en frecuencia de los 8 filtros



# Ejemplo “de juguete” en TF/Keras

## clasificación 2D

```
import matplotlib
from pylab import *
from keras.models import Sequential
from keras.layers import Dense, Activation
from keras.optimizers import SGD
from keras.utils.np_utils import to_categorical
%matplotlib inline
```

### Datos de entrenamiento

In [8]:

```
# creamos varias nubes de puntos 2D
X_train = vstack((randn(100,2)+array([-3,2]),
                  randn(100,2)-3,
                  randn(100,2)+array([0,4]),
                  randn(100,2)+array([-5,-6]),
                  randn(100,2)+array([0,-6])))

# las primeras son clase "1" y las restantes serán de clase "0"
Y_train_classes = kron([1,1,0,0,0],ones(100))

# generamos una codificación tipo "one-hot" (vectores de unos y ceros: un elemento para cada clase)
Y_train = to_categorical(Y_train_classes).squeeze()

Y_train.shape
```

Out[8]:

```
(500, 2)
```

### Datos de test

In [9]:

```
# creamos una retícula que recubra todo el espacio
# para comprobar los resultados de la clasificación en puntos intermedios
xi = linspace(-10,10,50)
xx,yy = meshgrid(xi,xi);
X_test = vstack((xx.flatten(),yy.flatten())).T
```

# Ejemplo “de juguete” en TF/Keras

## clasificación 2D

### Creamos el modelo (varias capas)

In [10]:

```
# creamos el modelo: varias capas
model = Sequential()
model.add(Dense(units=64, input_dim=2))
model.add(Activation("relu"))
model.add(Dense(units=64, input_dim=2))
model.add(Activation("relu"))
model.add(Dense(units=2))
model.add(Activation("softmax"))

# usamos "categorical_crossentropy", aporta más sensibilidad en problemas de clasificación
model.compile(loss='categorical_crossentropy', optimizer=SGD(lr=0.01, momentum=0.9, nesterov=True))

# ajustamos el modelo empleando el optimizador y función de coste anteriores
model.fit(X_train, Y_train, nb_epoch=50, batch_size=32, verbose=1)

Epoch 1/50
500/500 [=====] - 0s - loss: 0.4670
Epoch 2/50
500/500 [=====] - 0s - loss: 0.2924
Epoch 3/50
500/500 [=====] - 0s - loss: 0.2487
Epoch 4/50
500/500 [=====] - 0s - loss: 0.2237
Epoch 5/50
500/500 [=====] - 0s - loss: 0.2048
Epoch 6/50
500/500 [=====] - 0s - loss: 0.1916
Epoch 7/50
500/500 [=====] - 0s - loss: 0.1790
Epoch 8/50
500/500 [=====] - 0s - loss: 0.1679
Epoch 9/50
500/500 [=====] - 0s - loss: 0.1577
Epoch 10/50
500/500 [=====] - 0s - loss: 0.1531
Epoch 11/50
500/500 [=====] - 0s - loss: 0.1436
Epoch 12/50
500/500 [=====] - 0s - loss: 0.1316
Epoch 13/50
500/500 [=====] - 0s - loss: 0.1305
Epoch 14/50
...
```

# Ejemplo “de juguete” en TF/Keras

## clasificación 2D

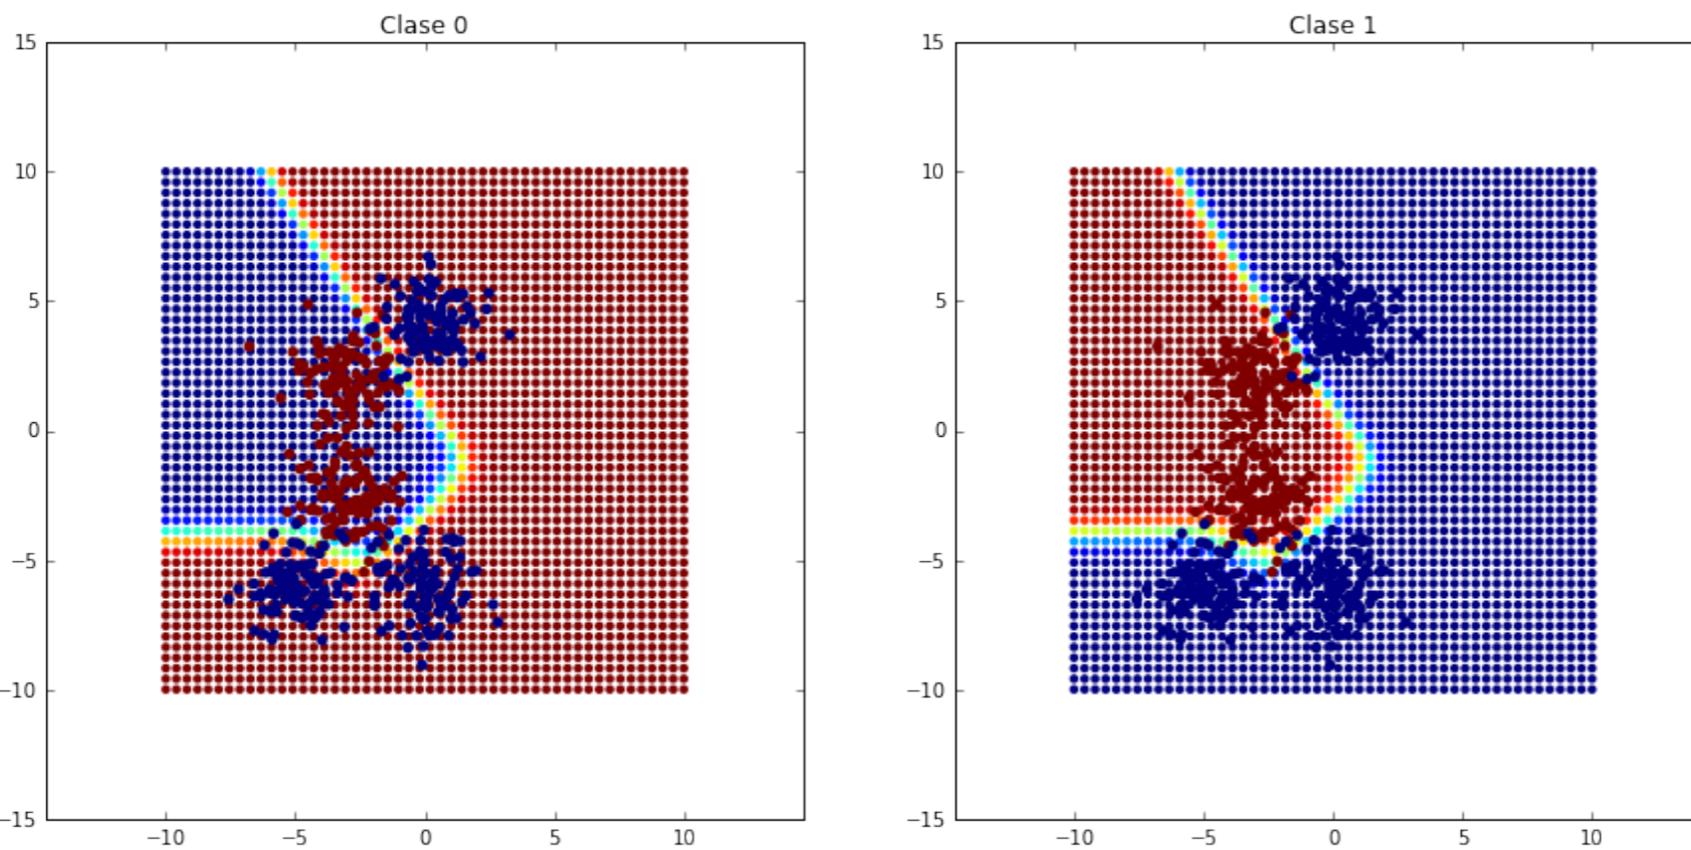
### Predicción

```
# predicción de las clases
classes = model.predict_classes(X_test, batch_size=32)

# predicción de las probabilidades de cada clase
class_probabilities = model.predict_proba(X_test, batch_size=32,verbose=0)

# dibujamos los resultados
figure(1,figsize=(15,7))
clf()
for i in range(2):
    subplot(1,2,i+1)
    scatter(X_test[:,0],X_test[:,1],c=class_probabilities[:,i],linewidhts=0)
    title('Clase %d'%i)
    axis('equal')
    scatter(X_train[:,0],X_train[:,1],s=30,c=Y_train_classes,linewidhts=0)
```

In [11]:



In [ ]:

<http://isa.uniovi.es/GSDPI>

## Inspección superficial

- Weimer D, Scholz-Reiter B, Shpitalni M. Design of deep convolution neural network architectures for automated feature extraction in industrial inspection. *CIRP Ann Manuf Technol* 2016;65(1):417–20.
- Ren R, Hung T, Tan KC. A generic deep-learning-based approach for automated surface inspection. *IEEE Trans Cybern* 2017;99:1–12.
- Masci J, Meier U, Ciresan D, Schmidhuber J, Fricout G, Mittal A. Steel defect classification with max-pooling convolution neural networks. *IEEE international joint conference on neural networks (IJCNN)* 2012;20:1–6.

## Detección e identificación de fallos

### Cajas de cambios

- Chen ZQ, Li C, Sanchez RV. Gearbox fault identification and classification with convolution neural networks. *Shock Vib* 2015;2:1–10.

### Cojinetes

- Shao H, Jiang H, Zhang X, Niu M. Rolling bearing fault diagnosis using an optimization deep belief network. *Meas Sci Technol* 2015;26(11):1–17.
- Gan M, Wang C, Zhu C. Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings. *Mech Syst Signal Process* 2016;72–73(2):92–104.

### Trenes

- Yin J, Zhao W. Fault diagnosis network design for vehicle on-board equipments of high speed railway: a deep learning approach. *Eng Appl Artif Intell* 2016;56:250–9.

## Maquinaria (predicción de desgaste, caja de cambios, cojinetes)

- Zhao R, Wang D, Yan R, Mao K, Shen F, Wang J. Machine health monitoring using local feature-based gated recurrent unit networks. *IEEE Transa Ind Electron* 2018;65(2):1539–48.

## Predicción de demanda eléctrica

- Qiu X, Zhang L, Ren Y, Suganthan PN, Amaratunga G. Ensemble deep learning for regression and time series forecasting. *IEEE symposium series on computational intelligence* 2014:1–6.

# Fin de la presentación